

UNIVERSIDAD POLITÉCNICA DE MADRID  
Escuela Técnica Superior de Ingenieros Navales



Marco de Inteligencia Artificial Generativa  
para Aplicación en la Sensórica Inalámbrica en  
el Buque

**TESIS DOCTORAL**

Presentada para optar al título de Doctor por:

**Arturo Benayas Ayuso**

Ingeniero Naval

Madrid, 2024



UNIVERSIDAD POLITÉCNICA DE MADRID  
Escuela Técnica Superior de Ingenieros Navales

**Doctorado en Ingeniería Naval y Oceánica**

**Marco de Inteligencia Artificial Generativa  
para Aplicación en la Sensórica Inalámbrica en  
el Buque**

**TESIS DOCTORAL**

Presentada para optar al título de Doctor por:

**Arturo Benayas Ayuso**  
Ingeniero Naval

Bajo la dirección de:  
Dr. Francisco Pérez Arribas  
Dr. Rodrigo Pérez Fernández

Madrid, 2024

Título: Marco de Inteligencia Artificial Generativa para Aplicación en la Sensórica Inalámbrica en el Buque

Autor: Arturo Benayas Ayuso

Programa de Doctorado: Ingeniería Naval y Oceánica

Dirección de Tesis:

Dr. Francisco Pérez Arribas, Profesor y Director del departamento de Arquitectura Naval, Construcción, Sistemas Navales y Oceánicos, Escuela Técnica Superior de Ingenieros Navales (Director)

Dr. Rodrigo Pérez Fernández, Profesor del departamento de Arquitectura Naval, Construcción, Sistemas Navales y Oceánicos, Escuela Técnica Superior de Ingenieros Navales (Director)

Revisores externos:

Tribunal de Tesis:

Fecha de Defensa de la Tesis:



*Dedico esta tesis a mis hijos, Marina, Vega y Adrián, que espero, algún día la encuentren inspiradora y la extiendan al siguiente nivel, ya que ellos han sido los causantes de que esta tesis se desarrolle en el marco de investigación de la inteligencia artificial.*



# Agradecimientos

A mi mujer, Patricia, y a mis hijos, Marina, Vega y Adrián, que me han apoyado y animado durante el proceso de escritura de la tesis doctoral, a veces con sus preguntas, otras con su paz, y siempre con su cariño y comprensión.

A mis padres, Alberto y Carmen, a mi hermano, Jorge, y familia en general porque me han enseñado a pensar, permitiéndome siempre dedicar tiempo a aprender y a ser mejor en todo lo que hago.

A mis directores de tesis, Francisco Lázaro Pérez Arribas y Rodrigo Pérez Fernández, con los que he andado más allá de las fronteras del saber, camino en el que hemos sufrido las penalidades y disfrutado de los éxitos, no siempre codo con codo, pero como una sola alma.

A mis profesores, pasados, presentes y futuros, porque el saber es una fuente de la que no quiero dejar de beber nunca y de la cual disfruto siempre con cada sorbo de nuevo conocimiento que adquiero.

A la perseverancia que me dio mi escuela, ETSI Navales, en la cual aprendí, no solo sobre barcos, sino también a ser resiliente y luchar por lo que uno ama.

A todas las personas, que, de una manera u otra, trabajaron y trabajan conmigo en las distintas actividades, ya que todos los días me inspiran y me llenan con su manera de ver y enfrentar la vida.

A mis alumnos, que siempre me enseñan algo nuevo, y no hay dos que sean iguales.

A todos mis amigos. Especialmente a aquellos que se han visto obligados a escucharme sobre todo lo que se desarrolla en las siguientes páginas, a veces con risas y otras con llantos, pero siempre con espíritu de comprensión y apoyo.

# Abstract

The advent of Industry 4.0 is precipitating a shift in the objectives of the shipbuilding industry. With regard to maritime vessels, this signifies an enhanced capacity for autonomous or semi-autonomous operations, which in turn necessitates a significant expansion in the deployment of sensor technology on board the ship, coupled with a parallel surge in the number of actuators.

In addressing this novel challenge (or, in some cases, not so novel), it is evident that regardless of the approach taken, there is a common requirement for a substantial increase in the number of cables to facilitate the transmission of the data and power required for each response.

The modifications to the vessel's design result in a notable reduction in its operational capability, equivalent to the weight of the high-load-capacity cables necessary to perform the vessel's semi-autonomous functions.

While certain materials, such as fiber optics, can reduce the overall weight of a system, they are only capable of transmitting data. Furthermore, the generation of a light beam requires a power supply with sufficient power for data transmission or intermediate elements that can amplify them in the process.

The threefold objective was to reduce the necessity for sensing to a minimum or as close as possible, to reduce the weight required for sensing, and to facilitate the design work by providing tools that could assist throughout the process, including the checking of the rules in the model itself.

In the case of actuators, it is not feasible to reduce the specific weight of the power supply. However, this is possible in the case of sensors, which can be multiplied by the combined use of data collection elements that do not require power and the use of RFID/BLE/UWB type sensors that can be passive or BAP (Battery-Assisted-Passive). The batteries of these sensors can last from months to years, depending on the data update needs that are established.

After all, during the study of existing elements, it was discovered that there was no user-oriented tool capable of assisting the design process without overwhelming the user. Consequently, research was initiated in the field of artificial intelligence (AI), with the aim of not only processing the data but also serving as a tool to assist the design process.

It was demonstrated that the generative AI framework, which integrates diverse models to offer a valuable solution to the designer, was the most appropriate given the tasks and feedback to be provided to the user.

It was therefore concluded that the optimal solution for sensors is the integration of fiber and copper, mixed cables, with radio frequency. In order to achieve effective design solutions, it was established that generative AI is indispensable in providing comprehensive support to the user throughout the design process. Consequently, a framework applicable to each suitable CAD was provided.

# Resumen

El marco de la Industria 4.0 está provocando un cambio en los objetivos de la industria naval. En lo que respecta a los buques, esto implica una mayor capacidad de para ser autónomos o semi-autónomos, lo que requiere un aumento sustancial de la sensórica aplicada al propio buque, junto con un aumento en paralelo del número de actuadores.

Al abordar este reto novedoso (o, en algunos casos, no tan novedoso), es evidente que cualquiera de los enfoques que se pueden aplicar, hay un requisito común, una gran necesidad de aumentar de manera considerable el número de cables para facilitar la transmisión de los datos y la energía necesarios para cada respuesta.

Estas modificaciones en el diseño del buque suponen una reducción significativa de su capacidad operativa, equivalente al peso de los cables de alta capacidad de carga necesarios para poder desempeñar la labor semi-autónoma del mismo.

Aunque ciertos materiales, como la fibra óptica, pueden reducir el peso total de un sistema, solo son capaces de transmitir datos. Además, la generación de un haz de luz requiere una fuente de alimentación con potencia suficiente para la transmisión del dato o de elementos intermedios que puedan amplificar el haz durante el proceso.

Los objetivos eran tres: en primer lugar, reducir la necesidad de sensorización al mínimo o lo más cerca posible; en segundo lugar, reducir el peso necesario para la misma; y en tercero, facilitar el trabajo de diseño proporcionando herramientas que pudieran ayudar a lo largo de toda esta fase, incluida la comprobación de las reglas en el propio modelo.

En el caso de los actuadores, no es posible reducir el peso específico de la alimentación. Sin embargo, sí es posible en el caso de los sensores, que pueden multiplicarse mediante el uso combinado de centros de colección de datos que sí requieren alimentación y el uso de sensores de tipo RFID/BLE/UWB que pueden ser pasivos o de tipo BAP (Battery-Assisted-Passive). Las baterías de estos sensores pueden durar de meses a años, según las necesidades que se establezcan para actualización del dato.

Al final, durante el estudio de los elementos existentes, se descubrió que no existía una herramienta orientada al usuario capaz de ayudar en la fase de diseño sin abrumarlo. En consecuencia, se inició una investigación en el campo de la inteligencia artificial (IA), con el objetivo no solo de procesar los datos, sino también de servir de herramienta de ayuda al proceso de diseño.

Se demostró que el marco de la IA generativa, que combina distintos modelos para ofrecer una solución útil al diseñador, era la más adecuada debido a las tareas y respuesta a facilitar al usuario.

Por tanto, la solución óptima para los sensores pasa por la integración de fibra y cobre, cables mixtos, con radiofrecuencia. Para lograr soluciones de diseño eficaces, es indispensable una IA generativa que proporcione un apoyo integral al usuario a lo largo de todo el proceso de diseño. Así pues, se proporciona un marco de trabajo aplicable a cada CAD adecuado.



# Tabla de Contenido

Agradecimientos . . . . .	v
Abstract . . . . .	vi
Resumen . . . . .	vii
Lista de Figuras . . . . .	xi
Lista de Tablas . . . . .	xiii
Abreviaturas y acrónimos . . . . .	xvi
<b>1 Introducción</b>	<b>1</b>
<b>2 Elementos IoS</b>	<b>11</b>
2.1 Sensor y transmisor . . . . .	13
2.1.1 Sensores Analógicos Modulares . . . . .	14
2.1.2 Sensores Analógicos Generadores . . . . .	15
2.1.3 Sensores Digitales de Posición . . . . .	17
2.1.4 Sensores Digitales Compuestos . . . . .	19
2.1.5 Transmisión del dato . . . . .	21
Fibra Óptica . . . . .	21
Usos habituales de la Fibra Óptica . . . . .	22
Ventajas de la Fibra Óptica . . . . .	22
Desventajas de la Fibra Óptica . . . . .	23
Cables mixtos - Fibra + Cobre . . . . .	23
2.1.6 Sensórica Inalámbrica . . . . .	24
2.1.7 Protocolos de comunicación . . . . .	25
Ondas ultrasónicas . . . . .	25
Óptica de Espacio Libre - Laser o infrarrojo . . . . .	26
LiFi . . . . .	30
Radiofrecuencia . . . . .	31
Bluetooth . . . . .	32
Wi-Fi . . . . .	35
ZigBee . . . . .	36
Sistema Global de Comunicaciones Móviles (GSM) . . . . .	36
Sistema Universal de Telecomunicaciones Móviles (UMTS) . . . . .	37
Redes 3G, 4G, 5G o 6G . . . . .	38
2.1.8 Banda Ultra Ancha (UWB) . . . . .	41

Aplicaciones . . . . .	42
2.1.9 RFID . . . . .	45
2.1.10 BLE . . . . .	47
2.2 Ciberseguridad . . . . .	51
2.2.1 Problemas de ciberseguridad asociados al IoT . . . . .	53
2.2.2 Principales conceptos de Blockchain y problemas de ciberseguridad . . . . .	55
2.2.3 Combinación de IIoT + Blockchain . . . . .	57
2.3 Inteligencia Artificial . . . . .	60
2.3.1 Natural Language Processing . . . . .	62
2.3.2 Deep Learning . . . . .	65
Deep Reinforcement Learning . . . . .	83
2.3.3 Variational Auto Encoder . . . . .	86
2.3.4 Generative Adversarial Networks . . . . .	87
<b>3 Materiales y métodos</b>	<b>89</b>
3.1 Materiales físicos . . . . .	90
3.1.1 Raspberry Pi . . . . .	90
3.1.2 Arduino One . . . . .	90
3.1.3 Otros materiales . . . . .	90
3.2 Materiales digitales . . . . .	91
3.2.1 Python . . . . .	91
3.2.2 TensorFlow . . . . .	91
3.2.3 NumPy . . . . .	91
3.2.4 SpaCy . . . . .	92
3.3 Metodología para la aplicación de la Inteligencia Artificial . . . . .	93
3.3.1 Marco conceptual . . . . .	94
3.3.2 Definición de la metodología: herramientas de diseño de buques, estudio en profundidad . . . . .	96
¿En qué etapas pueden ayudar las herramientas CAD en IoT? . . . . .	96
Cómo puede ayudar CAD en la distribución de etiquetas y sensores . . . . .	98
Reglas de diseño propias . . . . .	100
Elementos CAD/PLM que deben controlarse mediante IA y tablas base . . . . .	102
3.3.3 Modelo . . . . .	104
Arquitectura de la solución GenAI para CAD . . . . .	104
Conversión de un sistema CAD/PLM en un conjunto de sensores IoT . . . . .	105
Modelos GenAI utilizados en el caso a estudio . . . . .	107
3.3.4 Ajuste de hiperparámetros de cada red neuronal con Optimización Bayesiana . . . . .	111
Optimización de parámetros - Métodos estudiados . . . . .	111
Optimización Bayesiana para VAE . . . . .	112
Optimización Bayesiana para GAN . . . . .	115
<b>4 Resultados</b>	<b>119</b>
4.1 Estudio de ciberseguridad: Blockchain como primera capa . . . . .	119
4.1.1 Casa inteligente . . . . .	119

4.1.2	Smart Home Cluster para empresas de seguridad . . . . .	121
4.1.3	Actualización controlada para dispositivos IoT . . . . .	122
4.1.4	Resultados del caso de ciberseguridad . . . . .	123
4.2	Estudio de Inteligencia Artificial Generativa . . . . .	125
4.2.1	Definición de diccionarios . . . . .	126
4.2.2	Entrenamiento de las redes RNN . . . . .	127
4.2.3	Entrenamiento de los modelos S2SM . . . . .	128
4.2.4	Entrenamiento del GAN . . . . .	128
4.2.5	Aplicación al caso de ventilación y refrigeración de locales: Resultados	129
<b>5</b>	<b>Discusión</b>	<b>131</b>
<b>6</b>	<b>Conclusiones y trabajo futuro</b>	<b>133</b>
	<b>Referencias</b>	<b>139</b>
	<b>Anexos</b>	<b>145</b>



# Lista de Figuras

1.1	Una agrupación de las disciplinas de la Industria 4.0 . . . . .	4
1.2	Elementos IoT . . . . .	6
1.3	Elementos coordinados de la Industria 4.0 . . . . .	7
2.1	Elementos IoT . . . . .	12
2.2	Sensor de posición angular . . . . .	18
2.3	Composición de un cable FTTH . . . . .	23
2.4	Comparación de las bandas de frecuencia definidas por la OTAN, la IEEE y la UIT (Treinkvist, CC BY-SA 4.0, vía Wikimedia Commons) . . . . .	32
2.5	Tecnologías de la Industria 4.0 relacionadas con el IoT y la ciberseguridad [Benayas-Ayuso y col., 2021] . . . . .	51
2.6	Construcción de una red de dispositivos IoT virtualizados [Benayas-Ayuso y col., 2021] . . . . .	59
2.7	Ejemplo de árbol de palabras para obtención de la raíz de significado . . . . .	63
2.8	Ejemplo de marcado de tipología de palabras . . . . .	63
2.9	Ejemplo de marcado de clase de palabra . . . . .	64
2.10	Ejemplo de puzle de palabras . . . . .	64
2.11	Ejemplo de red completamente conectada . . . . .	78
3.1	Flujo de spaCy . . . . .	92
3.2	Flujo de la solución [Benayas-Ayuso y col., 2024] . . . . .	93
3.3	Marco conceptual [Benayas-Ayuso y col., 2024] . . . . .	94
3.4	Esquema de la solución propuesta [Benayas-Ayuso y col., 2024] . . . . .	104
3.5	Modelo de formación continua a partir del diseño y los requisitos [Benayas-Ayuso y col., 2024] . . . . .	108
3.6	Capas necesarias para el entrenar el modelo VAE [Benayas-Ayuso y col., 2024] . . . . .	110
4.1	Definición de blockchain para completar una red empresarial [Benayas-Ayuso y col., 2021] . . . . .	123
4.2	Creación de bloques y relaciones entre cadenas de bloques [Benayas-Ayuso y col., 2021] . . . . .	124



# Lista de Tablas

2.1	División de los sensores por características . . . . .	13
2.3	División de Sensores Analógicos Modulares . . . . .	14
2.5	División de Sensores Analógicos Generadores . . . . .	16
2.7	División de Electrodo de Ion Selectivo (ISE) . . . . .	17
2.9	División de Sensores Digitales (Encoder) . . . . .	17
2.11	Partes Sensores Digitales . . . . .	18
2.13	División de otros tipos de Sensores . . . . .	19
2.15	Tipos de cable de Fibra Óptica . . . . .	21
2.17	Recomendación ITU de división del espectro de radiofrecuencia . . . . .	31
2.19	Clasificación de los dispositivos Bluetooth por potencia [SIG, 2024] . . . . .	34
4.1	Ejemplo de diccionario implementado para CAD . . . . .	126
4.3	Ejemplo de diccionario implementado para PLM . . . . .	127

# Abreviaturas y acrónimos

## - A -

**AI** Artificial Intelligence

Inteligencia Artificial (ver también IA)

## - B -

**BAP** Battery-Assisted Passive

Elemento Pasivo Asistido por Baterías

**BLE** Bluetooth Low Energy

Bluetooth de Baja Energía

## - C -

**CAD** Computer Aided Design

Diseño Asistido por Ordenador

**CCD** Charged-Coupled Device

Dispositivo de Carga Acoplada

**CDMA** Code Division Multiple Access

Acceso Múltiple por División del Código

**CEI** Comisión Electrotécnica Internacional

**CIS** Contact Image Sensor

Sensor de Imagen Cercana

**CMOS** Complementary Metal-Oxide-Semiconductor

Semiconductor de óxido metálico complementario

## - D -

## - E -

**EBOM** Engineering Bill of Material

Lista de Materiales de Ingeniería

**EHF** Extremely High Frequency

Frecuencia Extremadamente Alta

**ELF** Extremely Low Frequency

Frecuencia Extremadamente Baja

**ERP** Enterprise Resource Planning

Sistema de Gestión de Recursos Empresariales

**EMI** Electromagnetic Interference

Interferencia Electromagnética

- **F** -

- **G** -

**GSM** Global System for Mobile Communications

Sistema Global de Comunicaciones Móviles

- **H** -

**HF** High Frequency

Frecuencia Alta

- **I** -

**IA** Inteligencia Artificial

**IEC** International Electrotechnical Commission

Comisión Electrotécnica Internacional (ver también CEI)

**IEEE** Institute of Electrical and Electronic Engineering

Instituto de Ingenieros Eléctricos y Electrónicos

**IIoT** Industrial Internet of Things

Internet de las Cosas Industrial

**IoS** Intenet of Ships

Internet de los barcos

**IoT** Internet of Things

Internet de las Cosas

- ITU** International Telecommunications Union  
Unión Internacional de Telecomunicaciones (organización)
- ISE** Ion Selective Electrode  
Electrodo de Ion Selectivo
- ISM** Industrial-Scientific-Medical  
Industrial-Científico-Médico
- J -
- K -
- L -
- LAN** Local Area Network  
Red de área local
- LDR** Light Dependant Resistor  
Resistencia Dependiente de la luz
- LF** Low frequency  
Frecuencia Baja
- LVDT** Linear Variable Differential Transformer  
Transformador Diferencial de Variación Lineal
- M -
- MAC** Medium-Access Control  
Control de Acceso al Medio
- MAN** Metropolitan Area Network  
Red de área metropolitana
- MBOM** Manufacturing Bill of Material  
Lista de Materiales de Fabricación
- MF** Medium frequency  
Frecuencia Media
- MOS** Metal-Oxide-Semiconductor

Semiconductor de oxido metálico

- N -

**NFC** Near Field Communication

Comunicación de Campo Cercano

**NTC** Negative Temperature Coefficient

Coefficiente Negativo de Temperatura

**N-Doped** Negative Doped

Dopaje negativo (del material semiconductor)

- O -

**OS** Operating System

Sistema Operativo

- P -

**PAN** Personal Area Network

Red de Área Personal

**PJM** Phase-Jitter Module

Módulo de Oscilación de Fase

**PLC** Programmable Logic Controller

Controlador Lógico Programable

**PLM** Product Lifecycle Management

Gestión del Ciclo de Vida del Producto

**POF** Plastic Optic Fiber

Fibra Óptica de Plástico

**PSK** Phase-Shift Keying

Modulación por Desplazamiento de Fase

**PTC** Possitive Temperature Coefficient

Coefficiente Positivo de Temperatura

**P & ID** Piping & Instrumentation Diagram

## Diagrama de Tuberías e Instrumentación

**P-Doped** Positive Doped

Dopaje positivo (del material semiconductor)

- Q -

**QIS** Quanta Image Sensor

Sensor de Imagen Cuántico

- R -

**RFID** Radio Frequency IDentification

Identificación por Radio Frecuencia

**RTD** Resistance Temperature Detector

Detector de Temperatura por Resistencia

- S -

**SCADA** Supervisory Control And Data Acquisition

Control de Supervisión y Adquisición de datos

**SCS** Storage Control System

Sistema de Control de Almacén

**SHF** Super High Frequency

Super Alta Frecuencia

**SIG** Special Interest Group (Bluetooth)

Grupo de Interés Especial (Bluetooth)

**SLF** Super Low Frequency

Super Baja Frecuencia

**SSIC** Ship System IoT Cell

Célula IoT de Sistema de Buque

- T -

**TDMA** Time Division Multiple Access

Acceso Múltiple por División del Tiempo

**THF** Tremendouslyly High Frequency  
Frecuencia Tremendamente Alta

**TTF** Telcordia Technical Forum  
Fórum Técnico Telcordia

- U -

**UHF** Ultra-High Frequency  
Frecuencia Ultra Alta

**ULF** Ultra Low Frequency  
Frecuencia Ultra Baja

**UMTS** Universal Mobile Telecommunications System  
Sistema Universal de Telecomunicaciones móviles

**UPM** Universidad Politécnica de Madrid (organización)

- V -

**VHF** Very High Frequency  
Frecuencia Muy Alta

**VLf** Very Low Frequency  
Frecuencia Muy Baja

- W -

**WAN** Wide Area Network  
Red de Área Extensa

**WIA** Wireless Industrial Applications  
Aplicaciones Industriales Inalámbricas

- X -

- Y -

- Z -



# Capítulo 1

## Introducción

La industria 4.0, aplicada al sector naval, establece un nuevo paradigma que debe ser estudiado desde un punto de vista multidisciplinar, es decir, no podemos aplicar una parte sin tener en cuenta las otras.

La tesis se basa en la aplicación del Internet de las Cosas (Internet of Things - IoT) a la construcción y explotación de un buque, de hecho, en dos conceptos: el dato y el análisis de este. Sin embargo, esto es solo una parte reducida del ecosistema de nuevas tecnologías que habilita la Industria 4.0, y, además, no está aislado, ya que requiere del resto de las capacidades a desarrollar debido a este nuevo paradigma. En los siguientes párrafos desarrollaremos un poco más esta idea así como los detalles que nos llevan a esta afirmación.

Este concepto está vivo y se basa en la integración de algo nebuloso como es el IoT. El IoT busca, esencialmente, la integración de lo físico -materiales, bienes, maquinaria y aparatos- con lo digital: recopilación, análisis y almacenamiento de datos. El IoT es un excelente ejemplo de integración porque cada *objeto* se integra individualmente con el sistema digital, pero también con la red en general (o Internet) en su conjunto [Liu y col., 2016][Benayas-Ayuso y Perez Fernandez, 2018b].

Por otro lado, la integración del IoT en el buque durante la fase de explotación es clave, de hecho, la máxima actual del transporte marítimo moderno es esta integración definida como: la unión de diferentes sistemas, procesos y datos para fomentar la eficacia y la rapidez ya sea en la fase de diseño, construcción o explotación del ciclo de vida de un buque [Kirsch, 2015][Benayas-Ayuso y Perez Fernandez, 2018b].

Gracias a toda una serie de tecnologías emergentes (Industria 4.0), la integración en buques y astilleros es cada vez más fácil y beneficiosa. Por ejemplo, muchos buques están ahora equipados con sensores avanzados que controlan la maquinaria, el consumo de combustible y las rutas, integrando estos datos con el puente para ofrecer a la tripulación la información que necesita para manejar el buque con eficacia; ayudando a su mantenimiento desde tierra con un sistema predictivo de fallos y en contacto permanente con técnicos que les pueden guiar en sus labores [Fernández y Muñoz, 2017][Benayas-Ayuso y Perez Fernandez, 2018b].

Una vez establecidos los detalles, nos planteamos los siguientes objetivos, que eran tres: en primer lugar, reducir la necesidad de sensorización al mínimo o lo más cerca posible; en segundo lugar, reducir el peso necesario para la misma; y en tercero, facilitar el trabajo de diseño proporcionando herramientas que pudieran ayudar a lo largo de toda esta fase, incluida la comprobación de las reglas en el propio modelo.

Para tratar de aportar luz, se establecen los siguientes puntos de trabajo:

1. Objetivo general: Propuesta de un estándar para la integración de la sensórica inalámbrica en la construcción naval focalizado en la ayuda a la reducción de costes desde el diseño básico hasta el mantenimiento del buque.
2. Objetivos específicos (los cuales han ido evolucionando debido a pandemias y otros elementos):
  - (a) Estudiar el estado del arte de la sensórica inalámbrica de radiofrecuencia (RFID).
  - (b) Estudiar las características de la sensórica inalámbrica para la aplicación en:
    - i. Fase de construcción del buque.
    - ii. Fase de explotación del buque.
  - (c) Estudiar el proceso de los datos para facilitar el gemelo digital (IA).
  - (d) Proponer un estándar para la integración de la sensórica inalámbrica en la construcción naval basado en un marco integrable de inteligencia artificial.

La integración entre la parte de diseño, basada en CAD, con la realidad constructiva nos obliga a mantener un diálogo constante entre lo digital y lo físico, en el que las herramientas de diseño y los modelos digitales coincidan con los materiales y las líneas de producción reales para construir buques de forma eficiente y económica. Al integrar estos dos ámbitos y hacer que lo físico sea *visible* y accesible en el ámbito digital, se puede optimizar la producción, lo que se traduce en ahorros de costes, tiempo y material. El IoT, en el contexto de la construcción naval, es una forma avanzada de control de existencias, así como de su estado en el astillero desde el almacén hasta cada uno de los talleres [Liu y col., 2016][Benayas-Ayuso y Perez Fernandez, 2018b].

Sin embargo, puede resultar difícil imaginar cómo podría funcionar un ecosistema de IoT en el contexto de un astillero. Como teoría, es atractiva, pero en la práctica puede ser difícil de entender, por no hablar de aplicar, lo que requiere un cambio de mentalidad y de la inversión, tanto de tiempo como de dinero. Al tratar con materias primas sencillas, los astilleros están muy lejos del mercado de bienes de consumo, por ejemplo, que puede adoptar fácilmente el IoT porque la funcionalidad digital, y por tanto la posibilidad de integración, está incorporada en los aparatos y dispositivos modernos [Banafa, 2018][Benayas-Ayuso y Perez Fernandez, 2018b].

Cuando estudiamos todos los puntos del IoT, nos damos cuenta que esta capacidad debe aplicarse de una manera completa para que sea útil en todas las fases del buque, más concretamente se basa en la aplicación de la misma para la sensorización del buque de manera que se pueda usar en otros campos de la industria 4.0, a saber: gemelo digital, realidad virtual, buque autónomo y realidad aumentada; durante las fases de construcción, entrenamiento de tripulaciones en sala o a bordo, o ayuda al mantenimiento predictivo o correctivo, esto último ya es una realidad en algunos buques. Todas estas aplicaciones requieren de identificadores/sensores para su funcionamiento, ya sean reales o virtuales que deben estar en el modelo y en la realidad material de los elementos del buque.

En el caso del buque autónomo, además, requiere de un segundo ciclo de IoT basado en actuadores que permitan su operación de manera independiente del control desde otro buque, vehículo (aéreo o submarino) o base de tierra. En esta parte, la necesidad de un sistema de verificación de seguridad, es decir, un segundo grupo de sensores que confirmen de manera independiente que la acción se ha completado, complica la solución, encarece su construcción, así como, aumenta su peso de manera significativa, y, en el caso de los buques, esto supone un cambio drástico en su capacidad de navegación y maniobra.

Aun así, el *pero* que se añade con el segundo grupo de sensores mejora la solución de manera importante haciendo que el propio barco sea un elemento fiable lejos del control directo.

Pero, por muy autónomo que sea nuestro buque, hay un detalle que siempre está presente y es importante, la comunicación del estado del barco a tierra. Este factor se ha de tener en cuenta, ya estemos estudiando el caso de buques autónomos o clásicos. Esta información es crítica ya que permite evolucionar el gemelo digital de tierra y predecir futuros mantenimientos, así como programar los mismos de manera eficiente y predictiva, y no correctiva, ayudando al armador a reducir los costes de estos y los días sin flete.

Las tecnologías utilizadas en la industria 4.0 son múltiples, pero en esta tesis solo desarrollaremos parcialmente algunas de ellas para poder mejorar la aplicación del IoT en cualquier industria, así como su uso en el ámbito Naval, desde fases tempranas hasta su explotación más completa.

El concepto, cuando ha ido evolucionando la tesis se ha centrado en que tipología de datos se pueden explotar de los sensores, como posicionarlos, como ayudar en su disposición mejorando la eficiencia y reduciendo el número de estos. También hemos realizado un estudio de la ciberseguridad aplicable y cuáles son las tecnologías que pueden ayudar en un primer momento, en este caso el Blockchain. Para poder realizarlo todo, se ha diseñado un marco coordinado de inteligencia artificial que ayuda en todos los campos, convirtiéndose este en el tema principal de la tesis.

Para poder conocer mejor el ámbito total de la Industria 4.0, las tecnologías que aplican al sector naval se han agrupado en la siguiente figura [Benayas-Ayuso y Perez Fernandez, 2019]:



**Figura 1.1:** Una agrupación de las disciplinas de la Industria 4.0

De todas las tecnologías mostradas, solo vamos a desarrollar durante la tesis aquellas que, aplicadas a la sensorización del buque, representan un campo de mejora directo, o aquellas requeridas por seguridad por la propia sensorización, ya sea como un estudio del arte de estas o profundizando en las que son base para el desarrollo de la tesis. A saber:

1. *Grandes almacenes o Lagos de datos (Data lakes)*: conjuntos de servidores orientados almacenar datos en cantidades ingentes de todos los generados por los elementos del sistema o sistemas en estudio. También enviarán datos hacia todos los elementos de estudio de estos. Esta tecnología está en desarrollo y mejora continua, debido a que es la base de la computación en la nube.
2. *Computación*: acción sobre los datos que se toman mediante la aplicación de cálculos directos y que están interrelacionados con los campos anteriores. Los resultados de la computación también se consideran datos válidos para estudio. La *computación* como acción se centra en el *dónde* más que en el *cómo*, por eso se suele dividir en:
  - (a) *En la nube (Cloud computing)*: permite derivar la computación a grandes centros de datos independientes que no tienen por qué estar a bordo del buque.
  - (b) *Local (Fog computing)*: se realiza en PLCs alimentados por uno o varios sensores/actuadores cerca del elemento o elementos que permiten las medidas.
  - (c) *Mixta o en el borde (Edge computing)*: los datos son distribuidos a centros de computación cercanos a los PLCs, centralizados por zonas o grandes conjuntos, sistemas o conjuntos de sistemas, que aúnan más datos de otros elementos. Un primer elemento que se usa en este nivel son los SCADA, computadores de gran capacidad industrial.

3. *Analítica de datos*: basados en metodologías estadísticas avanzadas que permiten el estudio de datos estructurados y no estructurados en toda su complejidad. Se han de utilizar metodologías que permitan el procesado de millones de datos de una manera eficiente. Los datos se leen de los *Lagos*, y los datos generados como resultado se guardan en los mismos.
4. *Inteligencia Artificial (IA)*: caso particular de la analítica de datos y la computación que permite el análisis de estos, el aprendizaje automático basado en los datos, así como la ayuda en la toma de decisiones.
5. *Ciberseguridad*: al transmitir tantos datos para su almacenamiento, proceso y toma de decisiones informada, todos los puntos de acceso, manipulación, transmisión y almacenaje son susceptibles de ataque, por lo que su protección será parte del propio proceso de IoT, no directamente, pero sí de manera indirecta o como consecuencia.

En si misma, la ciberseguridad no es una tecnología en si misma, sino una rama completamente nueva debido a las comunicaciones por internet. En ella se desarrollan muchas tecnologías de defensa frente a los múltiples ataques posibles a recibir.

Aquí la mencionamos como una parte del estudio en lo que se refiere a la parte de sensores conectados a una red del buque o astillero, con una metodología específica más básica. Se detallará más en posteriores capítulos.

Un estudio de ciberseguridad aplicable en el buque a gran escala o en el astillero requeriría, al menos, una tesis completa, ya que es una “tecnología” o conjunto de las mismas en auge.

6. *Blockchain*: es una tecnología usada para la certificación de documentos y archivos que permite el registro de los datos en una cadena no corruptible, por lo que segura. Esta tecnología está siendo base en sitios que necesitan seguridad inherente, como las criptomonedas o la comercialización de assets internacionales de manera segura.

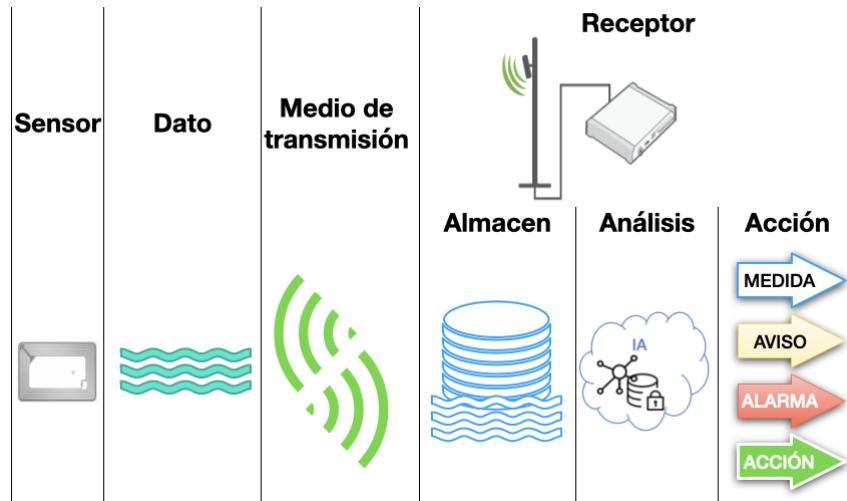
Hay otras tecnologías de la industria 4.0, como la fabricación aditiva, (ver Figura 1.1), pero no afectan directamente a la parte del IoT que se desarrolla en la tesis, pueden beneficiarse de los procesos descritos en la misma, pero quedan fuera de un alcance actual de este texto.

Todo lo anterior describe el ámbito de la sensorización del buque, y para que pueda usarse en los distintos campos en los que es base, ha de tener tres características básicas, debe ser:

- **Eficaz**, estableciendo el mínimo uso de sensores necesarios para la función a controlar, o que con solo uno se puedan acaparar varias funciones.
- **Eficiente**, dando la mejor solución posible para cada control/acción de un sistema.
- **Efectiva**, haciendo que la solución sea fiable.

Dentro de la tesis, a este trío de conceptos, nos referiremos como el paradigma de EEE, o el paradigma de las tres Es, ya que ninguna tiene sentido sin las otras dos.

Una vez establecidas las bases en las que operara el estudio de la sensórica a describir en la tesis, se ha de definir qué es IoT y en qué elementos se divide para entender la filosofía aplicada.



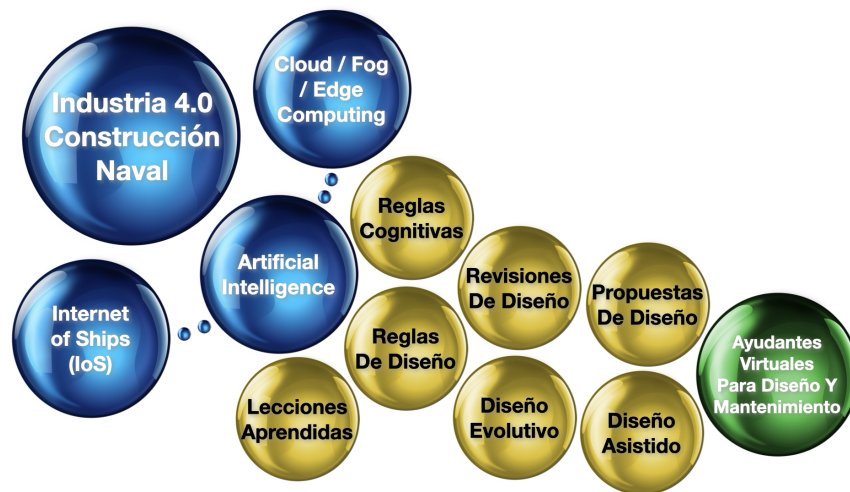
**Figura 1.2:** Elementos IoT

El IoT comprende 6 fases o elementos en su incorporación a cualquier industria (ver Figura 1.2):

1. **Sensor:** elemento que toma el dato y que lo convierte en un pulso electromagnético a ser transmitido.
2. **Dato:** valor medido por el sensor convertido en un pulso electromagnético a ser transmitido.
3. **Transmisión:** medio por el que ha de transmitirse el dato.
4. **Receptor:** elemento que recibe el dato por el medio de transmisión seleccionado. Este elemento suele tener la capacidad para realizar un análisis preliminar o local del dato a estudiar.
5. **Almacén del dato** (*Data Lake*): lugar donde se guarda una copia ordenada del dato tomado para su estudio o análisis profundo posterior.
6. **Acción:** resultado en el receptor del análisis del dato recibido. Puede ser de dos tipos:
  - *Informativa:* visualización del resultado de la medida en un panel, monitor, luz o incluso en una alerta.
  - *Reactiva:* acción a realizar por otro elemento. En función de qué o quién realice la acción, esta puede clasificarse en manual, guiada o autónoma, siendo las dos últimas acciones que representan un ciclo completo de retorno que debe ser estudiado como otro ciclo IoT independiente, pero desde el receptor, que actúa como sensor hacia los nuevos elementos sensores/actuadores.

En el caso a estudio, la parte más conflictiva se presenta en el dato, ya sea en la transmisión, su almacenamiento o el propio análisis. En el caso que la medida requiera una acción en tiempo real, o similar, de manera cercana, fog/edge computing, el análisis de este debe cumplir con el paradigma EEE expresado anteriormente. El crecimiento en las capacidades de proceso de los ordenadores y la disminución de su tamaño han hecho que toda la parte de la acción, si separamos el segundo ciclo IoT hacia el actuador, sea más sencilla y ligera, incluso en equipos ruggedizados para el entorno industrial, que es lo que requiere el sector naval para su implantación.

La tesis se ha centrado en conocer el estado del arte de los elementos implicados, que en el caso de sensores evoluciona muy rápido, así como en todas las tecnologías que pueden ayudar en su implantación y desarrollo dentro del entorno naval (IoS). Un detalle de los elementos considerados lo podemos ver en la figura 1.3 [Benayas-Ayuso y Perez Fernandez, 2019].



**Figura 1.3:** Elementos coordinados de la Industria 4.0

En sucesivos artículos publicados, debido a las vicisitudes del entorno industrial naval, se ha desarrollado un concepto aplicado que también se va a usar en esta tesis, el Internet de los Buques -Internet of Ships (IoS)-. Tal y como dice [Aslam y col., 2023], parafraseando su definición de IoT e IoS: “The IoT is composed of the following six basic building blocks (2C3SI): Communication, Computation, Semantics, Services, Sensing, and Identification, which deliver the functionality of the IoT technology. Likewise, based on the maritime application environment. ... The IoS consists of four building blocks, i.e., sensing, communications, computation, and services”.

Basándonos en estas definiciones, vamos a cubrir dos aplicaciones del Internet Industrial de las Cosas (IIoT) al sector de la construcción naval centradas en un uso único de los sensores en todo el ciclo de vida de los materiales y productos, reduciendo el proceso de sensibilización del buque en tiempo y coste.

Con este enfoque, cuando un material llega al almacén, en el astillero, es necesario asignarle alguna identificación, marcándolo y trazándolo en el sistema. Dependiendo del tipo de elemento, esta marca puede ser reutilizada o no. En los casos en los que se puede reutilizar, el diseñador debe seleccionar un sensor que pueda obtener una medida requerida, como la tensión o la temperatura, otras unidades de medida también pueden ser adecuados, aunque estas representan el conjunto de elementos sin batería más habitual [Benayas-Ayuso y Perez Fernandez, 2018a].

El departamento de compras recibe los pedidos de adelanto de material que se están usando en el diseño de buques con el fin de solicitar una pre-oferta para su compra, conocer el tiempo de entrega estimado y elegir entre distintos suministradores con cual ejecuta la opción. Debido a que se quiere aprovechar la llegada del material para marcarlo, y si es necesario añadirle los sensores, esta orden de ingeniería debe venir acompañada de una segunda opción de compra basada en los identificadores-sensores que van a acompañar a estos materiales. Esta acción también debe posicionar en el sistema de almacén y producción una orden de trabajo para que el personal del almacén de material fije un elemento especial de identificación pasiva por radiofrecuencia (Radio Frequency IDentification (RFID)) con fines de identificación y sensorización, cuando el material de la primera orden llegue [Benayas-Ayuso y Perez Fernandez, 2018a].

Un poco más adelante vamos a explicar en detalle la elección de los identificadores-sensores pasivos por RFID, ya que la tesis se va a centrar en ellos, pero como una pequeña introducción del porqué principal es que son baratos, tienen capacidades y se pueden fijar fácilmente al material, así como leer con un pequeño sensor o incluso con un teléfono inteligente [Benayas-Ayuso y Perez Fernandez, 2018a]. Los identificadores-sensores por cable o con batería presentan problemas de manejo o mantenimiento de los materiales en el almacén o su transporte a los distintos talleres.

Teniendo en cuenta que el identificador-sensor debe permanecer siempre adherido al material en la posición deseada, el proceso de fabricación debe mantener este elemento RFID intacto, o con un bajo impacto en el proceso de manipulación, lo que asegura, principalmente para los sensores RFID, que estén en perfecto estado para trabajar en el ciclo de vida real del buque [Benayas-Ayuso y Perez Fernandez, 2018a]. Este proceso debe ser previamente calculado de manera que no se deje nada al azar y se disminuya lo máximo posible a un estado de cero daños en el identificador-sensor.

Todos estos pasos marcan un camino complejo para los materiales en el proceso de compra-almacenamiento-manipulación-uso, así como nuevas metodologías de trabajo para los diseñadores de buques, constructores y otras personas implicadas en cualquier parte de la cadena de proceso.

Con esto, las herramientas o sistemas de software utilizados en la construcción naval deben cubrir los tres períodos bien definidos y separados del proceso del buque: la fase de diseño, la de construcción, y la de operación, en la que IoT establece una relación adicional de los elementos y procesos incluidos en cada fase [Benayas-Ayuso y Perez Fernandez, 2018a][Benayas-Ayuso y col., 2018].

Este tipo de diseño se sustenta a través de metodologías de trabajo específicas, entre las que destaca el Diseño Orientado a Sistemas de Ingeniería, o con su descripción y acrónimo en inglés, Model Based Systems Engineering (MBSE). El MBSE es una metodología desarrollada para resolver problemas que deben abordarse en sectores de alto valor añadido, como los productos de defensa o la ingeniería aeroespacial, que son también sectores de alto riesgo que requieren procesos de diseño y construcción robustos desde fases muy tempranas para reducir costes y garantizar la planificación de los trabajos con el calendario dentro del presupuesto.

La ingeniería de sistemas requiere el uso de tecnologías más específicas para aplicarse con eficacia. En ingeniería de sistemas, existen innumerables aplicaciones que pueden utilizarse para aportar soluciones en las distintas fases del ciclo de vida de un buque [Benayas-Ayuso y col., 2018].

Esta metodología requiere experiencia y un alto grado de disciplina, por lo que su implantación en cualquier astillero u oficina de diseño suele ser lenta y costosa, aunque los beneficios a la larga se materializarán en un incremento de la calidad del trabajo, así como una disminución de los errores debido a fallos de diseño, mejorando también la agilidad a la hora de incluir cambios en los buques en fase de diseño o construcción.

Es posible, debido al auge del mercado de la sensórica, que algún detalle quede obsoleto durante la redacción de esta tesis, pero se van a dar las claves más importantes a la hora de realizar un estudio de mercado de cada uno de los elementos implicados en el IoT de manera que se pueda hacer sin ningún problema dicho estudio a posteriori.



# Capítulo 2

## Elementos IoS

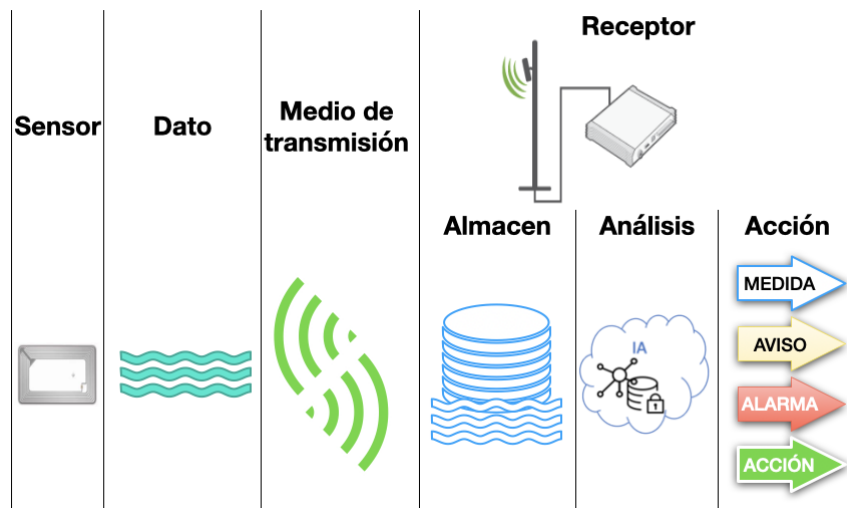
Tal y como explicamos en la introducción, el IoT comprende 6 fases o elementos en su incorporación a cualquier industria:

1. **Sensor:** elemento que toma el dato y que lo convierte en un pulso electromagnético a ser transmitido.
2. **Dato:** valor medido por el sensor convertido en un pulso electromagnético a ser transmitido.
3. **Transmisión:** medio por el que ha de transmitirse el dato.
4. **Receptor:** elemento que recibe el dato por el medio de transmisión seleccionado. Este elemento suele tener la capacidad para realizar un análisis preliminar o local del dato a estudiar.
5. **Almacén del dato** (*Data Lake*): lugar donde se guarda una copia ordenada del dato tomado para su estudio o análisis profundo posterior.
6. **Acción:** resultado en el receptor del análisis del dato recibido. Puede ser de dos tipos:
  - *Informativa:* visualización del resultado de la medida en un panel, monitor, luz o incluso en una alerta.
  - *Reactiva:* acción a realizar por otro elemento. En función de qué o quién realice la acción, esta puede clasificarse en manual, guiada o autónoma, siendo las dos últimas acciones que representan un ciclo completo de retorno que debe ser estudiado como otro ciclo IoT independiente, pero desde el receptor, que actúa como sensor hacia los nuevos elementos sensores/actuadores.

Debido a esto, se va a realizar un estudio detallado de cada uno de los elementos a describir, para mostrar claramente los detalles necesarios desarrollados en esta tesis.

Debido al auge del mercado de la sensórica, es posible que algún detalle quede obsoleto durante la redacción de esta tesis, pero se van a proporcionar las claves más importantes para llevar a cabo un estudio de mercado de cada uno de los elementos implicados en el IoT, de manera que dicho estudio pueda realizarse sin ningún problema a posteriori.

Para volver a tener presente los elementos implicados, también hemos recuperado la figura 2.1:



**Figura 2.1:** Elementos IoT

Nos vamos a centrar en la tesis en 3 campos, que son los que vamos a describir a continuación:

- **Sensor**, como elemento principal a estudiar para conocer el estado del arte, muy cambiante.
- **Medio transmisor**, como elemento que influye a la hora de seleccionar un tipo de sensor u otro.
- **Análisis del dato**, para ello nos centraremos en las técnicas de inteligencia artificial que son aplicables para detectar detalles no controlados o deducidos de los sensores empleados en nuestra red IoT.

También vamos a dedicar un capítulo a la ciberseguridad dentro de nuestra red, ya que, aunque no es parte directa del ecosistema IoT, cuando este necesita altas capacidades de computación, debido a la Inteligencia Artificial, es necesario identificar de manera clara nuestros sensores y si existen elementos ajenos a nuestro ecosistema.

## 2.1 Sensor y transmisor

El sensor es el elemento más importante de la secuencia de elementos en el IoT, ya que es el que obtiene el dato, y es el encargado de convertir la señal física del mundo en una señal eléctrica interpretable y entendible en nuestro sistema.

Estos se pueden distinguir por varias características, pero se han separado en dos grupos, señal y alimentación, que permite destacar los grandes grupos de clasificación en los suministradores:

**Tabla 2.1:** División de los sensores por características

Característica	División	SubDivisión
Señal	Analógico	Modulares Generadores
	Digital	
	Otros	
Alimentación	Sin alimentación	
	Cable	
	Radio Frecuencia reactivo	Pasivo BAP (Pasivo con ayuda por batería)
	Radio Frecuencia activo	Alimentado con batería

Los sensores también se pueden clasificar por la medida física que toman en los siguiente grandes grupos:

- Mecánico
- Térmico
- Magnético
- Eléctrico
- Óptico
- Químico

Ahora vamos a desarrollar cada uno de los grupos de la tabla 2.1 en los siguientes apartados, de manera que veamos cómo se van clasificando y las características de estos.

### 2.1.1 Sensores Analógicos Modulares

Son sensores que requieren alimentación, además de un circuito de conversión de la medida de analógico a digital. Se puede ver su clasificación en la tabla 2.3.

**Tabla 2.3:** División de Sensores Analógicos Modulares

Parámetro eléctrico	Tipo / Medida física
Capacitancia	Distancia y posición Presión, fuerza Acelerómetros Humedad Análisis químico (mezclas fluidas) Nivel de fluidos
Resistencia	Piezoresistivos (presión, fuerza) Potenciómetros (distancia, posición, ángulo) RTD - Resistance Temp. Detector (temperatura) Termistores NTC & PTC (temperatura) Fotorresistencias LDR (luminosidad) Higrómetros Resistivos o humistores (humedad) Detectores de gases Magneto resistivos (campo magnético)
Inductancia	Distancia y posición Espesores Presión, fuerza Acelerómetros
Transformadores diferenciales	LVDT Syncros Resolvers Inductosyn
Electromagnéticos	Velocidad Distancia Caudal

Dependiendo del valor físico a medir pueden ser sensibles a cambios en temperatura, así como que el paso de corriente por los mismos produce un calentamiento propio que debe tenerse en cuenta, por lo que los materiales y márgenes de medida afectan a la construcción del sensor.

Si estudiamos los *resistivos*:

- En el caso de sensores de temperatura tenemos dos tipos: materiales conductores y materiales semiconductores, cuyo comportamiento es diferente y nos aprovechamos de la capacidad del material de variar su conductividad con la temperatura.

- En el caso de sensores lumínicos, estos se ven muy afectados por la temperatura, por lo que hay que limitar mucho el rango de uso. Otro detalle es la velocidad de reacción, con el aumento de luminosidad es más rápida la variación de la conductividad, pero con la disminución, la variación es lenta.
- En el caso de los sensores de gases, es más extremo ya que dependen de manera directa de la humedad del local, así como de la temperatura de este. Para el segundo se suele añadir un circuito de compensación por temperatura, pero la humedad puede hacer que se produzcan falsos positivos.

El caso de los *capacitivos* es ligeramente diferente, ya que no suelen estar muy influidos por temperatura o campos magnéticos, ya que su límite físico lo pone la propia construcción el capacitor en forma y materiales.

En el caso de los *inductivos*, aunque son muy precisos y la humedad no les afecta, si los campos magnéticos parásitos de otros elementos cercanos, por lo que se deben estudiar los campos cercanos para su instalación. Funcionan muy bien en entornos industriales, especialmente en entornos con alta concentración de polvo y vibraciones, donde otros sensores fallan.

En el caso de los *transformadores lineales*, lo que más le afecta es la estabilidad de la fuente de alimentación, ya que el salto en las potencias es directamente proporcional a la entrada.

El último grupo, dentro de este tipo de sensores, son los *electromagnéticos*, cuya medida se basa en la ley de Faraday y en el efecto Hall. Como el caso de los inductivos, son muy robustos y se pueden usar en entornos industriales en los que haya polvo, humedad o vibraciones, pero se ven muy impactados por las corrientes parásitas, y otro detalle es la distancia de medida para las variaciones de campo, que es muy pequeña.

### 2.1.2 Sensores Analógicos Generadores

Este tipo de sensores no requieren alimentación, los materiales usados en su construcción son capaces de generar una señal eléctrica de salida. Una de las ventajas que ofrecen es que requieren menos cableado que los modulares, por lo que su instalación y mantenimiento son más sencillos.

Se suelen clasificar por la señal eléctrica emitida:

- *Carga eléctrica*: piezoeléctricos y piroeléctricos.
- *Tensión*: termopares y sensores de concentración de iones.

Los *piezoeléctricos* presentan muy buenas características de sensibilidad, pero son muy sensibles a la temperatura y la impedancia de salida es muy alta, por lo que se requiere acondicionar la señal de salida con un amplificador electrométrico.

Los *piroeléctricos* están centrados en la medida de temperaturas o radiación a distancia. Con esta capacidad también se usan para el control de personas o animales por infrarrojos, o la presencia de gases que absorben rayos infrarrojos. Suelen ser de tamaño pequeño y, como no requieren equilibrarse con la fuente de radiación, su tiempo de respuesta es más corto que los termopares y termistores.

Los *termopares* son elementos que miden por contacto del sensor con el elemento o fluido a tomar la temperatura. Se basan en el efecto *Seebeck*, por el cual se produce una diferencia de potencial (tensión) en la unión de dos metales que se someten a una diferencia térmica.

**Tabla 2.5:** División de Sensores Analógicos Generadores

Característica	División	Medida física
Carga eléctrica	Piezoeléctricos	Presión Acelerómetros Vibración Oscilación Impacto Compresión Tensión
	Piroeléctricos	Temperatura a distancia Potencia generada (fuentes radiactivas) Detección de gases (sensibles a infrarrojo) Radiación infrarroja (personas, animales)
Tensión	Termopares Electrodos de ion selectivo (ISE)	Temperatura Concentración de sustancias

Los termopares ofrecen muy buena fiabilidad a bajas temperaturas, mejor que los resistivos; no tienen problemas de autocalentamiento, ya que no requieren fuente de alimentación; son fiables y duraderos, y su tiempo de respuesta es muy pequeño, del orden de milisegundos.

Sin embargo, no todo son ventajas, cuando se toma la medida, debe asegurarse que la corriente que circula por el termopar sea reducida, la respuesta no es lineal y debe acondicionarse la señal, sin contar con que uno de los extremos debe estar a una temperatura estable de referencia.

Por último, los *Electrodos de Ion Selectivo* (ISE), se basan en la generación de una diferencia de potencial por la comparación de concentraciones del ion referencia y el fluido donde se encuentra nuestro ion a medir. El principio en el que se basan es la ecuación de Nerst.

Se suelen agrupar como en la tabla 2.7.

**Tabla 2.7:** División de Electrodo de Ion Selectivo (ISE)

Característica	División	Subdivisión
Electrodos Selectivos Primarios	Cristalinos	De membrana homogénea De membrana heterogénea
	No Cristalinos	De matriz rígida De matriz no rígida
Compuestos o de membrana múltiple	Sensores de gases De sustrato enzimático	
Membrana en contacto	Metal conductor Otro soporte conductor	

La división anterior se suele simplificar en:

- Membrana de vidrio
- Membrana de cristalina en estado sólido
- Membrana líquida
- Electrodo compuestos

### 2.1.3 Sensores Digitales de Posición

Los sensores digitales son aquellos que dan la medida ya en un valor usable dentro del mundo de la automática industrial. Se suelen usar para medir posiciones relativas o absolutas dentro de mecanismos, y esta es su clasificación.

Para poder estudiarlos con cierta facilidad, destacamos cuáles son sus parámetros para poder centrarnos en la precisión de cada uno de ellos 2.9:

**Tabla 2.9:** División de Sensores Digitales (Encoder)

Tipo	Parámetros
Incremental	Origen
	Desplazamiento
	Dirección
Absoluta	Posición binaria

Ambos sensores son similares en construcción, por lo que las partes comunes a ambos tipos de sensor son (tabla 2.11):

**Tabla 2.11:** Partes Sensores Digitales

Parte	Detalle
Cabezal	Electromagnético
Regla	Recta Circular
Codificación regla	Magnética Óptica Eléctrica Binaria
Fin de carrera	Sólo sensores incrementales

La principal diferencia es que los primeros, los incrementales, normalmente requieren recalibración con el tiempo y el uso. Solemos verlos en máquinas expendedoras y suelen hacer un recorrido hasta el fin de carrera para reiniciar su posición absoluta, que está guardada en el procesador del dato que los acompaña. En el caso de los de posición absoluta, este dato siempre está en el propio sensor, por lo que solo debemos procesar origen y destino para conocer el incremento.

Los primeros son más baratos, aunque el tiempo de proceso de recalibración sea más alto y puedan acumular errores si no se recalibran con cierta frecuencia. Los segundos son más caros y su tiempo de respuesta es menor, ya que siempre están disponibles y calibrados para actuar.



**Figura 2.2:** Sensor de posición angular

En la figura 2.2 se ve un sensor angular mixto, ya que puede tomar medidas absolutas e incrementales con alta sensibilidad. Usa el magnetismo como fuerza física para la medida y no requiere alimentación para su uso.

### 2.1.4 Sensores Digitales Compuestos

Este grupo de sensores está basado en otras propiedades electromagnéticas de los materiales en combinación con las vistas anteriormente. Suelen ser sensores compuestos y muy específicos para alguna función compleja concreta.

Se pueden agrupar en (ver tabla 2.13):

**Tabla 2.13:** División de otros tipos de Sensores

Tipo	Método	Medida
Semiconductores	Unión semiconductor	Temperatura Presión Luz Magnetismo Tensión
Imagen	Efecto Fotoeléctrico (CCD, CMOS, CIS, etc.)	Distancia Inspección Óptica Detección de presencia Espectrometría Reconocimiento facial Etc.
Radiación	Diferencia entre reflejada/absorbida	Distancia Velocidad Presencia Caudal sin contacto

Aprovechan las propiedades físicas de los semiconductores para obtener la medida del parámetro físico que se quiere estudiar, por lo que presentan la ventaja que integran en la misma etapa el acondicionamiento de la señal y la conversión analógico-digital. Están basados en las propiedades de los transistores para obtener las distintas medidas.

En el primer grupo, *uniones semiconductoras* se encuentra aquellos, que miden una magnitud física directa, como temperatura, luz, magnetismo, tensión. etc. Son la base de los chips usados en los sensores RFID.

En el caso de los sensores de imagen, existen múltiples tecnologías:

- *CCD (Charged-Coupled Device)*: son los primeros detectores de imagen, descubiertos en 1969 por William Boyle y George E. Smith. Son muy precisos. Se basan en la tecnología MOS (Metal-Oxide-Semiconductor) de condensadores con dopaje positivo (P-Doped), generando huecos que permiten circular mejor la electricidad. Se pueden encontrar en cámaras fotográficas, escáneres profesionales, sensores de distancia, fotografía astronómica, etc.
- *CMOS (Complementary Metal-Oxide-Semiconductor)*: son la alternativa al CCD. Mucho más baratos y permiten reducir el tamaño para la captación de la imagen. Son los más populares. También están basados en la tecnología MOS, pero con un dopaje negativo (N-Doped), permitiendo tener un electrón libre, por lo que mejoran también la transmisión eléctrica.
- *CIS (Contact Image Sensor)*: son sensores que permiten detectar objetos muy cercanos. Están integrados en escáneres portátiles ya que requieren poca distancia al objeto y poca potencia para funcionar.
- *QIS (Quanta Image Sensor)*: estos sensores están en fase de desarrollo, por lo que todavía están en el laboratorio. Cambian la detección de píxeles a *jots*, pudiendo tener del orden de miles de millones incluidos en un solo sensor. Su tecnología se basa en que cada *jot* puede detectar el fotón que incide sobre él. Los rangos de lectura permiten 1000 fps con una generación de datos de 1 Tb/s.

Los sensores por radiación se basan en el uso del efecto Doppler para realizar las medidas, enviando un haz de radiación y con un sensor especializado para ese propósito. Se clasifican en:

- *Radar*: emplean microondas para realizar la medida.
- *Ultrasonidos*: ondas acústicas en el rango de los 20kHz.
- *Óptica*: están basados en la emisión de infrarrojos para realizar la medida.

### 2.1.5 Transmisión del dato

Una vez que el dato ha sido obtenido por el sensor, debe transmitirse, por lo que habrá que *conectarlo* en nuestro sistema IoT para poder trabajar con él. En el sector naval, debido al entorno metálico de los buques se requiere que no haya interferencias por lo que los cables de datos van del sensor hasta el PLC, SCADA o elemento que lo va a procesar (fog/edge computing).

Dependiendo del tipo de buque, se usa cobre u otros materiales metálicos, como el aluminio, con las restricciones que impone de transmisión y peso; o, donde la transmisión del dato es vital, se usa fibra óptica como alternativa. A continuación, vamos a profundizar en este medio de transmisión ya que, debido al gran avance de la tecnología en este campo, puede ser una alternativa para cualquier tipo de buque para la transmisión del dato consolidado desde los elementos colectores de campo a cada uno de los centros de datos.

#### Fibra Óptica

La fibra óptica utiliza pulsos de luz en lugar de pulsos eléctricos para transmitir información, por lo que ofrece un ancho de banda cientos de veces mayor que los sistemas eléctricos tradicionales. El cable de fibra óptica puede protegerse con revestimiento y armadura para hacerlo resistente a las duras condiciones ambientales. De ahí que su uso se esté extendiendo en el sector naval militar para la transmisión de voz, vídeo y datos [John, 2021].

**Tabla 2.15:** Tipos de cable de Fibra Óptica

Tipo	Características	Usos
Monomodo (Vidrio)	Núcleo: 8,3 $\mu m$ Una longitud de onda Camino único Pocos reflejos de la luz Poca atenuación de la señal Más cara que la Multimodo	Conexiones de red a gran distancia
Multimodo (Vidrio)	Núcleo: 50 $\mu m$ y 62,5 $\mu m$ Varias longitudes de onda Multi vía Dos tipos (índice de refracción): - Índice escalonado - Índice graduado	Distancias cortas, cables conexión en redes LAN para audio/video
Plástico (POF)	Núcleo: 1 mm Índice de refracción escalonado Costes de conectores reducidos (10 %-20 %) Más duradera y fácil de instalar	Distancias cortas, cables conexión en redes LAN <i>lentas</i>

## Usos habituales de la Fibra Óptica

Debido a la calidad y sencillez de transmisión del dato, la fibra se está usando para las siguientes aplicaciones generales:

- *Telecomunicaciones:* La fibra óptica se utiliza mucho en este campo, ya que permite transferir datos de un lugar a otro, aunque la distancia sea grande, con una pérdida mínima de señal.
- *Centros de datos:* Las fibras ópticas desempeñan un papel importante en la conexión de servidores y dispositivos de red dentro de los centros de información.
- *Redes:* Los cables de fibra óptica se utilizan en redes de área local (LAN), redes de área metropolitana (MAN) y redes de área extensa (WAN) para interconectar ordenadores, conmutadores, enrutadores y otros sistemas comunitarios.
- *Imágenes médicas:* Las fibras ópticas se utilizan en medicina junto a endoscopios y láseres científicos para el diagnóstico por imagen y los abordajes quirúrgicos.

## Ventajas de la Fibra Óptica

- *Mayor ancho de banda y mayor velocidad:* el cable de fibra óptica admite un ancho de banda y una velocidad extremadamente altos. La gran cantidad de información que se puede transmitir por unidad de cable de fibra óptica es su ventaja más significativa.
- *Barato:* los kilómetros continuos de cable de fibra óptica son más baratos que las longitudes equivalentes de cable de cobre. Actualmente, el número de fabricantes ha subido, por lo que, al saturarse el mercado, el precio será más competitivo.
- *Más fina y ligera:* la fibra óptica es más fina y se puede estirar hasta diámetros más pequeños que el alambre de cobre, del orden de 4,5 veces. Su tamaño y peso son menores que los de un cable de cobre comparable en transmisión de datos, por lo que se adapta mejor en espacios reducidos.
- *Mayor capacidad de transporte:* como las fibras ópticas son mucho más finas que los hilos de cobre, se pueden agrupar más fibras en un cable de un diámetro determinado. Por lo que se puede dar servicio a más usuarios o más equipos con un grosor equivalente de cable de cobre.
- *Menores interferencias electromagnéticas (IME):* El cable óptico es resistente a las interferencias electromagnéticas, ya que la luz, como onda, está en una parte diferente del espectro de frecuencias usadas en comunicaciones.
- *Menor degradación de la señal:* la pérdida de potencia de la señal en la fibra óptica es menor que en el cable de cobre, por lo que se pueden usar cables más largos sin necesidad de amplificadores/repetidores de señal.
- *Señales luminosas:* a diferencia de las señales eléctricas transmitidas por cables de cobre, las señales luminosas de una fibra no interfieren con las de otras fibras del mismo cable de fibra. Esto se traduce en transmisiones digitales de mayor calidad y con menos interferencias.


- *Seguridad en las comunicaciones:* El cable de fibra óptica es muy difícil de pinchar porque no produce energía electromagnética. Estos cables de fibra óptica son muy seguros para transmitir datos.
- *Larga vida útil:* las fibras ópticas suelen tener un ciclo de vida más largo, de más de 100 años. Los elementos naturales corrosivos que afectan al cobre de manera natural no tienen impacto en la fibra óptica, alargando su vida útil.

### Desventajas de la Fibra Óptica

- *Baja potencia:* las fuentes emisoras de luz están limitadas a baja potencia. Aunque existen emisores de alta potencia para mejorar el suministro de energía, supondrían un coste adicional, no solo económico sino en energía requerida.
- *Fragilidad:* la fibra óptica es bastante frágil y más vulnerable a los daños que los cables de cobre. Al no ser dúctiles, no se pueden trenzar fuera del límite elástico de un sólido, vidrio.
- *Distancia en multiplicidad de señales:* la distancia entre el transmisor y el receptor debe ser corta en los cables multimodo y POF, que permiten la transmisión de múltiples señales a la vez, por lo que se necesitan repetidores para aumentar la señal. Este límite no afecta a los monomodo.

### Cables mixtos - Fibra + Cobre

Uno de los límites de la fibra óptica es la transmisión de energía para alimentar elementos como antenas, por lo que el ahorro que supone en cables coaxiales de cobre para la transmisión de la señal no es tan importante, ya que la alimentación hay que hacerla con cobre.



**Figura 2.3:** Composición de un cable FTTA

En este aspecto, han desarrollado cables mixtos en los cuales hay un núcleo de cables de fibra óptica para la transmisión de la señal y se usa como elementos que forman parte del mismo cable dos hilos de cobre para transmitir la potencia (ver figura 2.3). Este tipo de cables se denomina FTTA [TTF, 2014][TTF, 2009]. Su aplicación está muy extendida en el mundo

de las comunicaciones, para alimentación y emisión/recepción de las señales de datos, ya que permite paralelizar las distintas tecnologías: GSM, UMTS, LTE, 3G, 4G, 5G y la futura 6G con la alimentación de la antena, en un sólo cable más fino y sin interferencias entre la transmisión de potencia y la señal.

La fibra usada es monomodo, por lo que permite la transmisión a grandes distancias sin pérdidas de la señal de comunicaciones elegida; pero, el límite, lo pone el cobre para la alimentación de los elementos. Aun así, está diseñado para acoplarse de manera sencilla entre distintos cables, pudiendo completar por tramos el circuito.

Comercialmente se vende hasta en piezas de 3 metros a 50 metros, pero se puede hacer a medida, por lo que facilita la alimentación, así como la amplificación del pulso de luz. Este tipo de cables, están pensados para intemperie, por lo que se pueden aplicar en entornos marinos, siempre que su construcción esté de acuerdo con la normativa [IEC, 2019].

### 2.1.6 Sensórica Inalámbrica

En primer lugar, ¿qué sensores pueden considerarse sensores IoT? Para responder a esta pregunta, las definiciones más extendidas pueden resumirse como “*Cualquier tipo de sensor que pueda transmitir sus datos en una red, interna o externa, puede considerarse un sensor IoT*”. Cuando esto se aplica a un entorno industrial, estos sensores se convierten en sensores IIoT. Para poder considerarse dentro de la transmisión inalámbrica se ha de *trabajar en un medio fluido sin necesidad de cables*.

Aunando estos dos conceptos, se establece el marco de trabajo de la sensórica inalámbrica, *elementos que pueden transmitir sus datos en una red sin necesidad de cables*.

Basándose en esto, los sensores pueden utilizar, como tecnología inalámbrica de transferencia de datos [Loeffler y Gerhaeuser, 2013]:

- *Ondas ultrasónicas*
- *Óptica de Espacio Libre*
- *Wi-Fi*
- *Bluetooth*
- *ZigBee*
- Cualquier comunicación móvil celular como:
  - *Sistema Global de Comunicaciones Móviles (GSM)*
  - *Sistema Universal de Telecomunicaciones Móviles (UMTS)*
  - *Redes 3G, 4G, 5G o 6G*
- *Banda Ultra Ancha (UWB)*
- *Identificación por Radiofrecuencia (RFID)*
- Cualquier otro método estándar disponible aprobado por el Comité de Estándares IoT.

Esto se desarrollará en detalle en la sección 2.1.7

El paradigma que plantea el IoT presenta una serie de limitaciones que se pueden agrupar de la siguiente manera:

- *Límites por el dispositivo:*
  - Tamaño reducido.
  - Poca capacidad de proceso.
  - Consumo reducido de energía.
- *Limites debidos a la red de transmisión del dato:*
  - Problemas de propagación de las ondas.
  - Potencia máxima a usar en radiofrecuencias.
  - Interferencia propia o por otros dispositivos.
  - Conectividad itinerante y movilidad.

Esto lo que nos focaliza es en la necesidad de estudiar los protocolos de comunicación de manera que puedan responder a todas estas necesidades surgidas de los límites que nos impone este tipo de tecnología.

La sensórica inalámbrica en la que se basa la tesis se ha centrado en los protocolos específicos para el RFID (HF Y UHF) [2.1.9] y BLE [2.1.10], ya que el resto del espectro de comunicaciones requiere características no fácilmente integrables en un sistema de industria naval.

Estos se van a desarrollar en más detalle, pero, a continuación, se va a hacer un repaso de todos los protocolos de comunicación inalámbrica disponibles para ver otras alternativas de transmisión diferentes al cable, ya sea de fibra o cobre.

### **2.1.7 Protocolos de comunicación**

Ahora vamos a desarrollar cada uno de los protocolos de comunicaciones que los sensores pueden utilizar, como tecnología inalámbrica de transferencia de datos [Loeffler y Gerhaeuser, 2013].

#### **Ondas ultrasónicas**

Este método de comunicación se basa en la emisión de ondas mecánicas que se trasladan en un medio fluido o sólido, y que dependen de las características de este para su transmisión, atenuación o apantallamiento parcial o total.

Se emite un sonido de alta frecuencia, fuera del espectro de humanos y animales, para la transmisión del dato. Requiere equipos especiales de altavoz y micrófono, el receptor no requiere tanta potencia, pero el emisor sí, por lo que son elementos alimentados. Además, como son ondas mecánicas están expuestas a interferencias y escuchas fuera de control, por lo que la información debe estar codificada antes de su emisión.

Estos elementos solo se usan en entornos locales, en los que el receptor los codifica usando otro estándar para poder emitirlo a la red.

Es la base de las antenas de detección aérea como el radar o submarina/líquido como el sonar, para detección por eco de objetos, por lo que en esa aplicación el emisor y receptor están integrados en el mismo elemento. El resultado de esa *medición* es una imagen codificada que se transmite por un cable hasta una pantalla donde está el operario para su estudio e interpretación.

Este tipo de comunicación también se usa en los buques mediante la guía de onda, específica para una frecuencia de los comunicadores internos (Walkie-Talkie), de manera que las comunicaciones son fluidas en el barco, sin que estas queden expuestas alrededor del mismo.

### Óptica de Espacio Libre - Laser o infrarrojo

Este método de comunicación se basa en la dualidad onda partícula del fotón, como onda electromagnética de alta frecuencia (ver 2.1.7) y su interacción con el medio fluido o sólido translucido o transparente por el que circulan, y que dependen de las características de este para su transmisión, atenuación o apantallamiento parcial o total.

Cuando la instalación de un cable complica la solución, se puede optar por la Óptica de Espacio Libre (FSO - Free Space Optical), que es una tecnología de comunicación que usa un haz de luz (visible o infrarroja) en la atmósfera o el espacio [ESA, 2006], para transmitir información entre dos puntos alineados. Utilizando el mismo principio que los emisores para fibra óptica, un diodo emisor de luz o un láser se usan como fuente de transmisión de la información, en frecuencias del orden de los THz (Terahertz) del espectro, con longitudes de onda típicas de 850 nm a 900 nm. El receptor tiene una lente que proyecta el haz sobre un receptor de alta sensibilidad mediante un cable de fibra óptica. [Mikolajczyk y col., 2017][Garlington y col., 2005][HBBCL, 2009]

Dependiendo del uso, velocidad de transmisión y distancia se pueden usar distintos usos:

- Entre dispositivos pequeños, como móviles, se usó *IrDA* (Infrared Data Association), en la que hay un led emisor de infrarrojos y un receptor que permite la comunicación entre dispositivos. Es una tecnología que permite velocidades de transmisión muy pequeñas de 9,6 kbps a 4 Mbps.

Se han desarrollado estándares que permiten comunicaciones a 16 Mbps (VFIR), 96 Mbps (UFIR) y 512 Mbps (GigaIR), pero requieren más potencia.

El rango de trabajo depende de la potencia del dispositivo, el estándar son 2 m, pero para dispositivos de baja potencia 0,2 m y si se combinan del orden de 0,3 m.

Existen un conjunto de protocolos y capas de comunicación que aplican, pero todas se basan en la especificación de la capa base de la comunicación IrDA, que es la IrPHY (Infrared Physical Layer Specification). En ella se establece como se hace el enlace óptico, la modulación, codificación y comprobación del ciclo de redundancia (CRC). [IrDAJP, 2019][Willebrand y Ghuman, 2001]

- Los enlaces ópticos terrestres basados en laser infrarrojo pueden comunicarse a distancia de hasta 3 o 4 km, o incluso 7 km (dependiendo del fabricante), con velocidades de transmisión de 100 Mbps, si la distancia es menor 650 m, las velocidades pueden alcanzar el Gigabit. [BlackBox, 2024][DigitalAir, 2024][ECSystem, 2024][Willebrand y Ghuman, 2001]
- Los enlaces ópticos usados en el espacio pueden alcanzar distancias de miles de kilómetros [ESA, 2006] o incluso distancias interplanetarias [Jørgensen, 2003], para ello hay que utilizar telescopios ópticos como expansores de luz, como el Hubble.

Las aplicaciones actuales de esta tecnología son:

- Conexiones LAN-to-LAN en Campus con velocidades de Fast Ethernet o Gigabit Ethernet.
- Conexiones LAN-to-LAN en una ciudad. ejemplo, Red de área metropolitana.
- Para cruzar una vía pública u otras barreras imposibles para emisor y receptor.
- Rápido acceso a servicios de banda ancha de alta velocidad en las redes de fibra óptica.
- Instalación de redes Temporales (para eventos o para otros fines).
- Restablecer la conexión de alta velocidad rápidamente (en caso de desastres).
- Conexión Voice-data convergente.
- Para las comunicaciones entre naves espaciales, incluidos los elementos de una constelación de satélites.

Las ventajas que presenta son:

- Fácil instalación.
- Licencia libre de operación.
- Altas tasas de bits.
- Bajas tasas de error a nivel de bits.
- Inmunidad a las interferencias electromagnéticas (IME), ya que utiliza luz en vez de microondas.
- Operación de dúplex completo.
- Protocolo transparente.
- Muy seguro debido a la alta direccionalidad y bajo espesor del rayo. El haz de luz puede ser tan delgado que lo hace difícil de interceptar.
- Los datos que viajan a través de una conexión FSO suelen estar cifrados, por lo que la hace una alternativa de comunicación muy segura.
- No se necesita de una zona de Fresnel, es decir, no necesita un elipsoide sin interferencias para hacer la comunicación, ya que es una emisión concentrada.

Los problemas e inconvenientes de la misma son:

- *Dispersión*: Al ser un haz de luz, cuando atraviesan un material (partículas en suspensión en la atmósfera) se produce la separación en ondas de distinta frecuencia. Se destacan dos fenómenos:
  - *Dispersión de Rayleigh*: cuando las partículas atravesadas son mucho menores que la longitud de onda del haz de fotones. Este efecto hace que el haz láser no llegue al receptor completo, ya que se descompone. Este efecto es el que hace que el cielo tome distintos colores cuando la luz del sol atraviesa las nubes, si no hay dispersión se ven blancas, pero si se produce, aparecen colores anaranjados y rosas. Según la Ley de Rayleigh-Jeans se comprueba que el grado de dispersión es inversamente proporcional a la potencia cuarta de la longitud de onda de la luz, lo que produce que a mayor longitud de onda encontremos menor dispersión, y viceversa.
  - *Dispersión de Mie*: cuando las partículas atravesadas por la luz son mayores que un décimo de la longitud de onda del haz de fotones. Suele darse con niebla, humo, polución atmosférica, aerosoles. La luz se dispersa en todas direcciones, haciendo visible el haz, por lo que la atenuación es muy grande.
- *Absorción atmosférica*: las partículas de los distintos gases que componen nuestra atmósfera pueden absorber distintas longitudes de onda. Por ejemplo, el ozono absorbe la luz ultravioleta, concretamente la UVA. Se ha estudiado lo que se conoce como *ventanas atmosféricas*, que son longitudes de onda que son menos absorbidas por el aire, estas son:  $[3 \mu m, 4 \mu m]$  y  $[8 \mu m, 12 \mu m]$ .
- *Fenómenos meteorológicos*: cambian la composición de la atmósfera por la que se transporta el haz de luz, por lo que cambian las *ventanas*. En estos casos, la dispersión del rayo no es tan importante como la atenuación de este. Por eso, hay que estudiar cada fenómeno por separado:
  - *Lluvia*: es un elemento atenuador del haz de luz, con unos 6 dB/Km para una lluvia de 25 mm/h. Esto se debe porque el radio de las gotas de agua es mucho mayor la longitud de onda.
  - *Nieve*: Estas tienen un tamaño mayor que la lluvia, ya que son cristales de hielo, por lo que, dependiendo de la copiosidad y tamaño de copo, se produce una atenuación de  $[3 \text{ dB/Km}, 30 \text{ dB/Km}]$ . Debido al efecto de atenuación, en zonas de nieve se reduce de manera drástica la distancia máxima de enlace para mantener la velocidad de red.
  - *Niebla*: En el caso de la niebla, la dispersión de Mie es el fenómeno más importante, ya que el tamaño de partícula es similar al de la longitud de onda. La atenuación de la señal debida a la dispersión del haz es de  $[10 \text{ dB/Km}, 100 \text{ dB/Km}]$ , por lo que hay que controlar la longitud de enlace para mantener la capacidad de transmisión del dato.  
En días de niebla densa, o zonas donde se produzcan al amanecer, se pueden alcanzar los 270 dB/Km, por lo que hay que estudiar la meteorología local para poder establecer enlaces de alta calidad y transmisión del dato.

- *Turbulencias y fuentes de calor*: el calor excesivo también representa un problema para la transmisión de haces de luz, ya que la densidad del aire varía haciendo que estos tomen trayectorias parabólicas, lo cual supone un problema de alineación de emisor y receptor. En las zonas desérticas, se produce debido a esto el fenómeno de los espejismos, que hace que se amplifiquen elementos lejanos o que aparezcan, lo que simula un charco de agua, sin embargo, es el aire produciendo la misma reflexión que una superficie acuosa. La trayectoria formada por los haces de luz tiene una curvatura que es proporcional al gradiente de la temperatura respecto a la referencia. Como el calentamiento se causa a nivel superficial, se producen, además, turbulencias y vientos en el aire que hacen que el haz no se propague de manera correcta.
- *Otros*:
  - Puntos de estabilidad de viento.
  - Polución de las ciudades, *smog*, que es la mezcla de niebla y polución.
  - Zonas de sombra en la ruta del haz luminoso.
  - Luces de fondo, cercanas al receptor.
  - Centelleo en el emisor (*scintillation* en inglés), haciendo que el haz no salga en la dirección correcta.
  - Cuando el sol se posiciona detrás del transmisor, puede hacer que no se reciba la señal.

Todo esto produce un aumento considerable de la ratio de error en la transmisión, así como una atenuación en la señal recibida.

Los fabricantes han propuesto una serie de medidas para paliar esto, como arquitecturas multi haz de manera que hay más de un emisor y receptor de manera que se asegure que la misma señal llega más de una vez. Hay prototipos de alta potencia para zonas de gran contaminación, lluvias persistentes, nieblas, etc., en las que se usan longitudes de onda de 1550 nm. Se suelen usar láseres de clase 1 o 1M, que son seguros para el ojo humano, mantienen el medio ambiente limpio de contaminaciones lumínicas. Otro detalle implementado en los productos actuales es el uso de sistemas de ganancia automáticos que permiten ajustar los elementos emisor/receptor a las condiciones atmosféricas del momento, aumentando la fiabilidad en condiciones adversas. [BlackBox, 2024][DigitalAir, 2024][ECSysstem, 2024]

Otros usos de los infrarrojos son para la detección de buques en la noche. En el mar, la detección por radar a veces no es efectiva y requiere de ayudas, por lo que, si generamos imágenes mediante infrarrojos y las procesamos mediante tecnologías de Reconstrucción Morfológica de Escala de Grises y post procesamos con metodologías de Variación total de puntos relativos, conseguimos distinguir mediante los infrarrojos elementos lejanos [D. Lu y col., 2024]. Por lo que el infrarrojo se convierte en una fuente de dato a ser procesado en sí mismo y no una fuente de transmisión, a no ser que queramos considerar los objetos como elementos sensores de reflexión de los rayos infrarrojos.

## LiFi

El Li-Fi (también escrito como LiFi) es una tecnología de comunicación inalámbrica que utiliza la luz emitida por LEDs para transmitir datos y posición entre dispositivos. El término fue acuñado por primera vez por Harald Haas durante una charla TEDGlobal en Edimburgo en 2011.

El Li-Fi es un sistema de comunicación por luz capaz de transmitir datos a alta velocidad en los espectros de luz visible, ultravioleta e infrarrojo. En su estado actual, solo se pueden utilizar lámparas LED para transmitir datos en luz visible. [pureLiFi, 2024]

Desde la perspectiva del usuario final, la tecnología es similar al Wi-Fi (2.1.7), con la diferencia técnica de que el Wi-Fi utiliza radiofrecuencia para inducir una tensión eléctrica en una antena para transmitir datos, mientras que el Li-Fi utiliza la modulación de la intensidad de la luz para transmitir datos. [pureLiFi, 2024]

Las comunicaciones de luz visible (VLC) funcionan apagando y encendiendo la corriente de los LED a una velocidad muy alta, más allá de la capacidad de percepción del ojo humano. Las tecnologías que permiten la itinerancia entre varias células Li-Fi, también conocidas como *handover*, pueden permitir una transición fluida entre Li-Fi. Las ondas de luz no pueden atravesar las paredes, lo que se traduce en un alcance mucho más corto y un menor potencial de pirateo en comparación con el Wi-Fi. No siempre es necesaria la línea de visión directa para que el Li-Fi transmita una señal, y la luz reflejada en las paredes puede alcanzar los 70 Mbit/s. [pureLiFi, 2024]

Tanto el Wi-Fi como el Li-Fi transmiten datos a través del espectro electromagnético, pero mientras que el Wi-Fi utiliza ondas de radio, el Li-Fi utiliza luz visible, ultravioleta e infrarroja. Los investigadores han alcanzado velocidades de transmisión de datos de más de 224 Gbit/s, mucho más rápidas que la banda ancha rápida típica en 2013. Se espera que el Li-Fi sea diez veces más barato que el Wi-Fi. El primer sistema Li-Fi disponible comercialmente se presentó en el Mobile World Congress de 2014 en Barcelona.

Aunque los LED Li-Fi tendrían que mantenerse encendidos para transmitir datos, podrían atenuarse por debajo de la visibilidad humana sin dejar de emitir luz suficiente para transportar datos. Este es también uno de los principales cuellos de botella de la tecnología cuando se basa en el espectro visible, ya que se limita al propósito de la iluminación y no se ajusta idealmente a un propósito de comunicación móvil, dado que otras fuentes de luz, por ejemplo, la luz solar, interferirán con la señal. [pureLiFi, 2024]

Dado que el alcance de onda corta del Li-Fi es incapaz de atravesar las paredes, sería necesario instalar transmisores en todas las habitaciones de un edificio para garantizar una distribución uniforme del Li-Fi. Los elevados costes de instalación necesarios para cumplir este requisito y lograr un nivel de viabilidad de la tecnología son uno de los posibles inconvenientes. Aun así, se sigue trabajando para mejorar esta tecnología. [pureLiFi, 2024]

## Radiofrecuencia

Tal y como lo define la Real Academia Española: “**Radiofrecuencia:** *femenina*, palabra compuesta de *radio* y *frecuencia*. Cada una de las frecuencias de las ondas electromagnéticas empleadas en radio comunicación.” [RAE, 2014]. Siguiendo la definición de la ITU, se obtiene el límite superior de este tipo de ondas: “*Ondas radioeléctricas* u *ondas hertzianas*: Ondas electromagnéticas, cuya frecuencia se fija convencionalmente por debajo de 3.000 GHz, que se propagan por el espacio sin guía artificial.” [ITU, 2020]


Este método de comunicación se basa en la transmisión de una onda de energía electromagnética en un medio fluido o sólido en el que circulan, y que dependen de las características de este para su transmisión, atenuación o apantallamiento parcial o total. Debido a esto, hay que dividir el espectro por debajo de los 3.000 GHz para poder ordenar los usos, por lo que, basándonos en las recomendaciones del ITU, el espectro de radio frecuencia se divide en [ITU, 2015][tabla 2.17]:

**Tabla 2.17:** Recomendación ITU de división del espectro de radiofrecuencia

Símbolo	#	Rango	Amplitud	Abreviatura
ELF	-1	]0.03 Hz, 0.3 Hz]	]10 <sup>7</sup> km; 10 <sup>6</sup> km]	<i>B.Gm</i>
	0	]0.3 Hz, 3 Hz]	]10 <sup>6</sup> km; 10 <sup>5</sup> km]	<i>B.hMm</i>
	1	]3 Hz, 30 Hz]	]10 <sup>5</sup> km; 10 <sup>4</sup> km]	<i>B.daMm</i>
SLF*	2	]30 Hz, 300 Hz]	]10 <sup>4</sup> km, 1,000km]	<i>B.Mm</i>
ULF	3	]300 Hz, 3 kHz]	]1,000km; 100km]	<i>B.hkm</i>
VLF	4	]3 kHz, 30 kHz]	]100km; 10km]	<i>B.Mam</i>
LF	5	]30 kHz, 300 kHz]	]10km; 1km]	<i>B.km</i>
MF	6	]300 kHz, 3 MHz]	]1km; 100m]	<i>B.hm</i>
HF	7	]3 MHz, 30 MHz]	]100m; 10m]	<i>B.dam</i>
VHF	8	]30 MHz, 300 MHz]	]10m; 1m]	<i>B.m</i>
UHF	9	]300 MHz, 3 GHz]	]1m; 1dm]	<i>B.dm</i>
SHF	10	]3 GHz, 30 GHz]	]1dm; 1cm]	<i>B.cm</i>
EHF	11	]30 GHz, 300 GHz]	]1cm; 1mm]	<i>B.mm</i>
THF*	12	]300 GHz, 3 THz]	]1mm; 100μm]	<i>B.dmm</i>
	13	]3 THz, 30 THz]	]100μm; 10μm]	<i>B.cmm</i>
	14	]30 THz, 300 THz]	]10μm; 1μm]	<i>B.μm</i>
	15	]300 THz, 3.000 THz]	]1μm; 0,1μm]	<i>B.dμm</i>

\*Nuevas denominaciones no incluidas en el estándar ITU 2015.8

A parte de la división de la ITU, que es la más completa, existen otras divisiones parciales del espectro. Si comparamos las bandas definidas según los estándares de la ITU, IEEE y EU/NATO/US ECM (2.4):



**Figura 2.4:** Comparación de las bandas de frecuencia definidas por la OTAN, la IEEE y la UIT (Treinkvist, CC BY-SA 4.0, vía Wikimedia Commons)

Aunque la división de la ITU entra en el espectro del infrarrojo, por encima de los 3 THz, y las ondas entre 3 GHz y 3 THz, se pueden considerar de los dos grupos, radiofrecuencia e infrarrojo, nosotros nos vamos a centrar en las frecuencias de comunicación que pueden ser usadas como medios para los sensores IoT.

ver sección 2.1.9.

## Bluetooth

El Bluetooth es un estándar de tecnología inalámbrica de corto alcance que facilita el intercambio de datos entre dispositivos fijos y móviles a corta distancia, lo que permite construir redes de área personal (Personal Areal Network - PAN). En su funcionamiento más habitual, la potencia de transmisión se limita a 2,5 milivatios, lo que le confiere un alcance muy limitado, de hasta 10 metros. Bluetooth emplea ondas de radio de frecuencia ultra alta (UHF) operando en frecuencias entre 2,402 y 2,480 GHz, o entre 2,400 y 2,4835 GHz, incluyendo bandas de guarda de 2 MHz en la parte inferior y 3,5 MHz en la superior. Esto se encuentra en la banda de radiofrecuencia industrial, científica y médica (ISM) de 2,4 GHz de uso global no licenciada (pero sí regulada) de corto alcance.

Se utiliza principalmente como alternativa a las conexiones por cable para la transferencia de datos entre dispositivos portátiles cercanos y para conectar teléfonos móviles y reproductores de música con auriculares inalámbricos, entre otros usos.

Se ha creado un grupo, el Bluetooth Special Interest Group (SIG), para la supervisión y control del uso del Bluetooth como vía de comunicación. Está formado por más de 35.000 empresas que representan a diversos sectores, como las telecomunicaciones, la informática, las redes y la electrónica de consumo. El Instituto de Ingenieros Eléctricos y Electrónicos (IEEE) estableció el estándar Bluetooth como IEEE 802.15.1, pero debido a diversos problemas ha abandonado la tarea de mantenimiento del estándar, dejándola en el Bluetooth SIG. Este se encarga de supervisar el desarrollo de la especificación, gestionar el programa de cualificación y proteger las marcas registradas.

Para que un fabricante pueda comercializar un dispositivo como dispositivo Bluetooth, debe cumplir las normas establecidas por el Bluetooth SIG. Se aplica una red de patentes a la tecnología, que se licencia a dispositivos individuales que cumplen los requisitos. En 2021, se fabricaron 4.700 millones de chips de circuitos integrados Bluetooth al año. El Bluetooth se probó por primera vez en el espacio en 2024, en una primera prueba prevista para la mejora de las capacidades del IoT.

Para más información sobre la aplicación al IoT, ver sección **2.1.10 BLE**, *Bluetooth Low Emissions* o *Bluetooth de baja frecuencia* que se está usando en este momento en este tipo de dispositivos, ya que requiere poca potencia y su eficacia es muy elevada, de hecho, compite con otras RF destinadas a los sensores inalámbricos.

La tecnología de radio Bluetooth se denomina como espectro ensanchado de difusión de frecuencia. La base de esta transmisión es la división del dato a transmitir en paquetes, los cuales viajan por los 79 canales estándar en los que se ha diseñado, de manera que cada paquete viaja por un canal. Cada canal tiene una anchura de banda de 1 MHz. Por lo general, realiza 1600 saltos por segundo con adaptación de salto frecuencia (ASF) habilitada, en inglés se llama Adaptive Frequency-Hopping (AFH). La aplicación al BLE cambia, por lo que es más simple, generando un ancho de banda de 2 MHz, lo que permite la reducción a 40 canales de transmisión.

Originalmente, la modulación mediante frecuencia de desplazamiento gaussiana (GFSK) era el único sistema de modulación disponible. Desde la introducción de Bluetooth 2.0 + EDR, la modulación  $\pi/4$ -DQPSK (Differential Quadrature Phase-Shift Keying) y 8-DPSK (Differential Phase-Shift Keying) también pueden utilizarse entre dispositivos compatibles. Los dispositivos que funcionan con GFSK se dice que lo hacen en modo de tasa de transmisión básica (BR), en el que es posible alcanzar una tasa de bits instantánea de 1 Mbit/s. El término *Enhanced Data Rate* (EDR) se utiliza para describir el esquema  $\pi/4$ -DPSK (EDR2) y 8-DPSK (EDR3), que pueden transferir 2 y 3 Mbit/s, respectivamente. En 2019, Apple publicó una extensión llamada HDR que soporta tasas de datos de 4 Mbit/s (HDR4) y 8 Mbit/s (HDR8) usando  $\pi/4$ -DQPSK en canales de 4 MHz con la tecnología Forward Error Correction (FEC).

El Bluetooth presenta una arquitectura: maestro/esclavo, a esta estructura de red se le conoce con el nombre de piconet (red bluetooth). Todos los dispositivos dentro de una piconet utilizan el reloj proporcionado por el maestro como base para el intercambio de paquetes. El reloj del maestro tiene un periodo de 312,5  $\mu s$ , y dos periodos hacen un slot de 625  $\mu s$ ; dos slots hacen un par de slots de 1250  $\mu s$ . En el caso más simple de paquetes de un solo slot, el maestro transmite en slots pares e interpreta los datos en slots impares. El esclavo, por su parte, recibe en los intervalos pares y transmite en los intervalos impares. Los paquetes pueden tener uno, tres o cinco slots, pero en todos los casos la transmisión del maestro comienza en slots pares y la del esclavo en slots impares. Esto no aplica al BLE, introducido en la especificación 4.0, que utiliza el mismo espectro de forma diferente.

Un dispositivo BR/EDR Bluetooth maestro puede comunicarse con un máximo de siete dispositivos en una piconet (una red informática ad hoc que utiliza la tecnología Bluetooth), aunque no todos los dispositivos alcanzan este máximo. Los dispositivos pueden cambiar de rol de forma acordada y el esclavo puede convertirse en el maestro (por ejemplo, un auricular

que inicia una conexión con un teléfono necesariamente debe comenzar como maestro, ya que es el iniciador de la conexión, pero puede actuar como esclavo posteriormente).

La especificación base de Bluetooth también contempla la conexión de dos o más piconets para formar una scatternet (red de redes Bluetooth), en la que ciertos dispositivos desempeñan simultáneamente el papel de maestro/líder en una piconet y el de esclavo en otra.

En cualquier momento, es posible transferir datos entre el dispositivo maestro y otro dispositivo (excepto con el modo de *transmisión de uso limitado* activo). El dispositivo maestro elige qué dispositivo esclavo va a utilizar; con normalidad, cambia rápidamente de uno a otro en un bucle. Como el maestro es el que elige qué esclavo se va a dirigir, mientras que un esclavo, en teoría, debería escuchar en cada intervalo de recepción, ser un maestro es una carga más ligera que ser un esclavo. Es posible ser maestro de siete esclavos y ser esclavo de más de un maestro. La especificación es vaga en cuanto al comportamiento requerido en las scatternets.

Los dispositivos Bluetooth se clasifican por potencia de la siguiente manera, ver en tabla 2.19.

**Tabla 2.19:** Clasificación de los dispositivos Bluetooth por potencia [SIG, 2024]

Clase	Maximum permitted power	
	mW	dBm
<b>1</b>	10-100	+10 - +20
<b>1.5*</b>	2,5-10	+4 - +10
<b>2</b>	1-2,5	0 - +4
<b>3</b>	0,01-1	-20 - 0

\*La clase 1.5 se suele incluir en la 1 para BR/EDR

Ahora estamos en el último estándar 6.0, pero la mayor parte de los dispositivos que usamos suelen tener entre el 4.0 y 5.4, ya que este estándar se ha liberado en verano de 2024.

## Wi-Fi

Es parte del espectro de la radio frecuencia. Es una familia de protocolos de redes inalámbricas basados en el estándar IEEE 802.11, que se utilizan habitualmente para la conexión en red de dispositivos de área local y el acceso a Internet. Estos protocolos permiten a los dispositivos digitales cercanos intercambiar datos mediante ondas de radio. Se trata del tipo de redes informáticas más extendidas, utilizadas en todo el mundo en redes domésticas y de pequeñas oficinas para enlazar dispositivos y proporcionar acceso a Internet mediante rúters inalámbricos y puntos de acceso inalámbricos en lugares públicos, como cafeterías, hoteles, bibliotecas y aeropuertos.

Wi-Fi es una marca comercial de la Wi-Fi Alliance, que restringe el uso del término “Wi-Fi Certified” a los productos que superan con éxito las pruebas de certificación de interoperabilidad marcadas por la alianza. El hardware no conforme o no certificado se denomina simplemente WLAN (Wireless Local Area Network), y puede o no funcionar con dispositivos certificados.

Los dispositivos compatibles pueden conectarse entre sí a través de puntos de acceso inalámbricos, así como con dispositivos cableados con conexión a Internet. Las distintas versiones de Wi-Fi están especificadas por varios estándares de protocolo IEEE 802.11, con diferentes tecnologías de radio que determinan las bandas de radio, los alcances máximos y las velocidades que pueden lograrse. El Wi-Fi suele utilizar las bandas de radio UHF de 2,4 gigahercios (120 mm) y SHF de 5 gigahercios (60 mm), con la banda SHF de 6 gigahercios utilizada en las nuevas generaciones del estándar; estas bandas se subdividen en múltiples canales. Los canales se pueden compartir entre redes, pero dentro del alcance, solo un transmisor puede transmitir en un canal a la vez.

Las bandas de radio de Wi-Fi funcionan mejor para el uso en línea de visión. Muchos obstáculos comunes, como paredes, pilares, electrodomésticos, etc., pueden reducir mucho el alcance, pero esto también ayuda a minimizar las interferencias entre distintas redes en entornos con muchos emisores. El alcance de un punto de acceso es de unos 20 m en interiores, mientras que algunos puntos de acceso afirman tener un alcance de hasta 150 m en exteriores. La cobertura de un punto de acceso puede ser tan pequeña como una habitación con paredes que bloqueen las ondas de radio o tan grande como muchos kilómetros cuadrados utilizando múltiples puntos de acceso superpuestos con itinerancia permitida entre ellos. Con el tiempo, la velocidad y la eficiencia espectral de Wi-Fi han aumentado. A partir de 2019, algunas versiones de Wi-Fi que funcionan con el hardware adecuado a corta distancia pueden alcanzar velocidades de 9,6 Gbit/s (gigabit por segundo).

Si nuestro sensor está incorporado en un elemento que permite la transmisión Wi-Fi, podremos usarlo para comunicar los datos y compartirlos de manera cercana, o en el caso que el receptor esté conectado a Internet, de manera lejana.

## **ZigBee**

Zigbee es una especificación basada en el estándar IEEE 802.15.4 para un conjunto de protocolos de comunicación de alto nivel utilizados para crear redes de área personal con radios digitales pequeñas y de baja potencia, como en la automatización del hogar, la recopilación de datos de dispositivos médicos y otras necesidades de baja potencia y bajo ancho de banda, diseñadas para proyectos a pequeña escala que necesitan conexión inalámbrica. Por lo tanto, Zigbee es una red ad hoc inalámbrica de baja potencia, baja velocidad de transmisión de datos y proximidad (es decir, área personal).

La tecnología definida por la especificación Zigbee pretende ser más sencilla y menos costosa que otras redes inalámbricas de área personal (WPAN), como Bluetooth o redes inalámbricas más generales, como Wi-Fi (o Li-Fi). Sus aplicaciones incluyen interruptores de luz inalámbricos, monitores de energía domésticos, sistemas de gestión del tráfico y otros equipos industriales y de consumo que requieren transferencia de datos inalámbrica de corto alcance y baja velocidad.

Su bajo consumo de energía limita las distancias de transmisión a entre 10 y 100 metros de línea de visión, dependiendo de la potencia de salida y las características ambientales. Los dispositivos Zigbee pueden transmitir datos a largas distancias pasando los datos a través de una red de malla de dispositivos intermedios para llegar a otros más distantes. Zigbee se utiliza normalmente en aplicaciones de baja velocidad de datos que requieren una batería de larga duración y una red segura (las redes Zigbee están protegidas por claves de cifrado simétricas de 128 bits). Zigbee tiene una velocidad definida de hasta 250 kbit/s, más adecuada para transmisiones intermitentes de datos desde un sensor o dispositivo de entrada.

Zigbee se concibió en 1998, se estandarizó en 2003 y se revisó en 2006. Su nombre hace referencia a la danza de las abejas melíferas al regresar a la colmena.

## **Sistema Global de Comunicaciones Móviles (GSM)**

El Sistema Global para las Comunicaciones Móviles (GSM) es un estándar desarrollado por el Instituto Europeo de Normas de Telecomunicación (ETSI) para describir los protocolos de las redes celulares digitales de segunda generación (2G) utilizadas por dispositivos portables, como teléfonos móviles y tabletas. El GSM es también una marca comercial propiedad de la Asociación GSM. GSM también puede referirse al códec de voz Full Rate.

Se implantó por primera vez en Finlandia en diciembre de 1991 y, a mediados de la década de 2010, se convirtió en un estándar mundial para las comunicaciones móviles, con una cuota de mercado superior al 90 % y presencia en más de 193 países y territorios.

Las redes 2G se desarrollaron como sustitución de las redes celulares analógicas de primera generación (1G). El estándar GSM describía originalmente una red digital de conmutación de circuitos optimizada para la telefonía de voz full dúplex. Con el tiempo, se amplió para incluir comunicaciones de datos, primero mediante transporte por conmutación de circuitos y, luego, por transporte de datos en paquetes a través del Servicio General de Radio por Paquetes (GPRS), y Velocidades de Datos Mejoradas para la Evolución GSM (EDGE).

Posteriormente, el 3GPP desarrolló las normas UMTS de tercera generación (3G), seguidas de las normas LTE Advanced de cuarta generación (4G) y 5G de quinta generación, que no forman parte de la norma GSM del ETSI.

A finales de la década de 2010, varios operadores de todo el mundo comenzaron a cerrar sus redes GSM. Sin embargo, debido a la gran difusión de la red, el acrónimo «GSM» se sigue utilizando como término genérico para referirse a la plétora de tecnologías de telefonía móvil G que evolucionaron a partir de ella.

### Sistema Universal de Telecomunicaciones Móviles (UMTS)

El sistema universal de telecomunicaciones móviles (Universal Mobile Telecommunications System, UMTS) es una de las tecnologías usadas por los teléfonos móviles de tercera generación, sucesora de GPRS, debido a que esta tecnología (evolución de GSM) no podía evolucionar para prestar servicios considerados de tercera generación.

Aunque inicialmente se concibió para su uso en teléfonos móviles, la red UMTS no se limita a estos dispositivos y puede utilizarse en otros.

Sus tres grandes características son las capacidades multimedia, una elevada velocidad de acceso a Internet (que también le permite transmitir audio y vídeo en tiempo real) y una transmisión de voz con calidad equiparable a la de las redes fijas. Además, dispone de una variedad de servicios muy extensa.

El sistema UMTS permite introducir a muchos más usuarios en la red global y aumentar la velocidad a 2 Mbps por usuario móvil.

Está siendo desarrollado por 3GPP (3rd Generation Partnership Project), un proyecto común en el que colaboran ETSI (Europa), ARIB/TIC (Japón), ANSI T-1 (Estados Unidos), TTA (Corea del Sur) y CWTS (China). Para alcanzar su aceptación global, el 3GPP va introduciendo el UMTS por fases y versiones anuales. La primera versión se presentó en 1999 y describía transiciones desde las redes GSM. En 2000, describió transiciones desde IS-95 y TDMA. La ITU se encarga de establecer el estándar para que todas las redes 3G sean compatibles.

UMTS ofrece los siguientes servicios:

- **Facilidad de uso y bajos costes:** UMTS proporcionará servicios de uso fácil y adaptable para abordar las necesidades y preferencias de los usuarios, una amplia gama de terminales para realizar un fácil acceso a los distintos servicios y un bajo coste de los servicios para asegurar un mercado masivo. Por ejemplo, el roaming internacional y la capacidad de ofrecer diferentes formas de tarificación.
- **Nuevos y mejorados servicios:** los servicios de voz mantendrán una posición dominante durante varios años. Los usuarios exigirán a UMTS servicios de voz de alta calidad junto con servicios de datos e información. Las proyecciones muestran una base de abonados a servicios multimedia que experimentará un fuerte crecimiento hacia el año 2010, lo que también posibilita servicios multimedia de alta calidad en áreas carentes de estas posibilidades en la red fija, como zonas de difícil acceso. Un ejemplo de esto es la posibilidad de conectarse a Internet desde el terminal móvil o desde el ordenador

conectado a un terminal móvil con UMTS.

- **Acceso rápido:** la principal ventaja de UMTS frente a la segunda generación móvil (2G) es su capacidad para soportar altas velocidades de transmisión de datos, de hasta 144 kbit/s en vehículos de gran velocidad, 384 kbit/s en espacios abiertos en la periferia y 7,2 Mbit/s con baja movilidad (en el interior de edificios) [cita requerida]. Esta capacidad, sumada al soporte inherente del protocolo de Internet (IP), se combina poderosamente para prestar servicios multimedia interactivos y nuevas aplicaciones de banda ancha, tales como los servicios de videotelefonía y videoconferencia, y la transmisión de audio y vídeo en tiempo real.

El sistema UMTS soporta velocidades máximas de transferencia de datos teóricas de 42 Mbit/s cuando se implementa HSPA (Evolved HSPA +) en la red. Los usuarios de las redes desplegadas pueden esperar una tasa de transferencia de hasta 384 kbit/s para los terminales de lanzamiento '99 (R99) (la versión original de UMTS) y de 7,2 Mbits/s para los teléfonos con conexión HSDPA (High Speed Downlink Packet Access). Estas velocidades son significativamente más rápidas que los 9,6 kbit/s de un solo canal de datos conmutados por circuitos de error corregido por error GSM, los múltiples canales de 9,6 kbit/s en HSCSD y los 14,4 kbit/s para canales CDMAOne.

Desde 2006, las redes UMTS en muchos países han sido o están en proceso de ser actualizadas con acceso de paquetes de enlace descendente de alta velocidad (HSDPA), a veces conocido como 3,5 G. En la actualidad, el HSDPA permite velocidades de transferencia de enlace descendente de hasta 21 Mbit/s. También se está avanzando en la mejora de la velocidad de transferencia del enlace ascendente con el HSUPA (High-Speed Uplink Packet Access). A largo plazo, el proyecto 3GPP Long Term Evolution (LTE) planea mover UMTS a velocidades de 4G de 100 Mbit/s hacia abajo y 50 Mbit/s, usando una tecnología de interfaz aérea de próxima generación basada en multiplexación ortogonal de división de frecuencia.

Las primeras redes UMTS para consumidores se lanzaron en 2002, haciendo hincapié en las aplicaciones móviles proporcionadas por las operadoras de telecomunicaciones, como la televisión móvil y la videollamada. Las altas velocidades de datos de UMTS ahora se utilizan con mayor frecuencia para el acceso a Internet: la experiencia en Japón y en otros lugares ha demostrado que la demanda de vídeo por parte de los usuarios no es alta y que el contenido de audio y vídeo proporcionado por las TELCO ha disminuido en popularidad en favor del acceso a Internet de alta velocidad, ya sea directamente en un auricular o conectado a un ordenador a través de Wi-Fi, Bluetooth o USB.

### Redes 3G, 4G, 5G o 6G

La extensión de las redes GSM y UMTS ha pasado a llamarse en función de las distintas generaciones. Esto permite a dispositivos con capacidades de comunicación a través de tecnologías inicialmente destinadas a móviles, transmitir sus datos a los receptores de estos. Aunque la sensorica estudiada en esta tesis se basa en la comunicación inalámbrica de baja potencia, debido a que los elementos colectores de información de estos pueden tener baterías o conexión a la red eléctrica y antenas de transmisión con estas capacidades, se hace un recorrido básico por las características de cada *Generación* de red de comunicaciones.

### **Red 3G**

La tecnología de telecomunicaciones móviles inalámbricas de tercera generación (3G) representa la tercera iteración de la tecnología. La 3G supone una actualización de las redes 2G, 2,5G, GPRS y 2,75G Enhanced Data Rates for GSM Evolution, y ofrece una transferencia de datos más rápida y una mejor calidad de voz.

Esta red se basa en un conjunto de normas utilizadas para dispositivos móviles y servicios y redes de telecomunicaciones móviles que cumplen las especificaciones de las Telecomunicaciones Móviles Internacionales-2000 (IMT-2000) establecidas por la Unión Internacional de Telecomunicaciones. La 3G se utiliza para diversas aplicaciones, como la telefonía vocal inalámbrica, el acceso móvil a Internet, el acceso inalámbrico fijo a Internet, las videollamadas y la televisión móvil. Las redes de telecomunicaciones 3G son capaces de soportar servicios que proporcionan una velocidad de transferencia de información de al menos 144 kbit/s. Las iteraciones posteriores de 3G, frecuentemente denominadas 3,5G y 3,75G, también facilitan el acceso móvil de banda ancha a velocidades de varios Mbit/s para teléfonos inteligentes y módems móviles, por ejemplo, en ordenadores portátiles. Esto garantiza que sea adecuada para llamadas de voz inalámbricas, acceso móvil a Internet, acceso inalámbrico fijo a Internet, videollamadas y tecnologías de televisión móvil.

Ha surgido una nueva generación de estándares celulares aproximadamente cada diez años desde la introducción de los sistemas 1G, entre 1979 y principios y mediados de los ochenta. Cada generación se distingue por la introducción de nuevas bandas de frecuencia, mayores velocidades de transmisión de datos y tecnología de transmisión no retro compatible. Las primeras redes comerciales 3G se introdujeron a mediados de 2001.

### **Red 4G**

El 4G representa la cuarta generación de tecnología de redes celulares de banda ancha, que sucede al 3G y precede al 5G. Un sistema 4G debe ofrecer las capacidades definidas por la Unión Internacional de Telecomunicaciones (UIT) en IMT Advanced. Entre las aplicaciones potenciales y actuales se incluyen, entre otras, el acceso móvil modificado a la web, la telefonía IP, los servicios de juegos, la televisión móvil de alta definición, las videoconferencias y la televisión en 3D.

No obstante, en diciembre de 2010, la UIT amplió su definición de 4G para englobar la evolución a largo plazo (LTE), la interoperabilidad mundial para el acceso por microondas (WiMAX) y el acceso evolucionado a paquetes de alta velocidad (HSPA+). La norma WiMAX se desplegó comercialmente por primera vez de forma masiva en Corea del Sur en 2006 y, desde entonces, se ha implantado en la mayoría de las regiones del mundo.

La versión inicial de la norma LTE se implementó por primera vez en Oslo (Noruega) y Estocolmo (Suecia) en 2009, y desde entonces se ha implantado en la mayor parte del mundo. Sin embargo, se ha debatido si las versiones iniciales de estas tecnologías deben considerarse 4G. El estándar celular inalámbrico 4G fue definido por la UIT y especifica las características clave del estándar, incluida la tecnología de transmisión y las velocidades de datos.

El 4G ofrece velocidades de hasta 150 Mbit/s de descarga y 50 Mbit/s de subida, mientras que el 3G tenía una velocidad máxima de 7,2 Mbit/s de descarga y 2 Mbit/s de subida. En 2022, la tecnología 4G representaba el 60 % de todas las conexiones móviles del mundo.

### **Red 5G**

En el campo de las telecomunicaciones, la 5G representa la quinta generación de estándares tecnológicos para redes celulares. Las compañías de telefonía móvil la desplegaron por primera vez a escala mundial en 2019 y sucedió a la tecnología 4G, que proporciona conectividad a la mayoría de los teléfonos móviles actuales.

Al igual que sus predecesoras, las redes 5G son redes celulares, en las que el área de servicio se divide en regiones geográficas discretas, denominadas células. Todos los dispositivos inalámbricos 5G dentro de una célula se conectan a Internet y a la red telefónica a través de ondas de radio, utilizando una estación base y antenas dentro de la célula. Las nuevas redes ofrecen mayores velocidades de descarga, con una velocidad máxima de 10 gigabits por segundo (Gbit/s) cuando solo hay un usuario en la red. El 5G tiene un ancho de banda mayor que el 4G, lo que le permite ofrecer velocidades más rápidas y conectar más dispositivos, mejorando así la calidad de los servicios de Internet en zonas saturadas de usuarios.

Se prevé que las redes 5G se conviertan en una fuente destacada de servicios generales de Internet, compitiendo con los proveedores existentes, como Internet por cable. Además, el 5G facilitará el desarrollo de aplicaciones novedosas en los ámbitos de la Internet de las cosas (IoT) y de máquina a máquina. Cabe señalar que los teléfonos móviles con capacidad 4G no pueden utilizar las redes 5G.

### **Red 6G**

En el campo de las telecomunicaciones, el término «6G» se utiliza para referirse a una futura norma técnica para una tecnología de comunicación inalámbrica de sexta generación.

Será la sucesora prevista de la 5G (IMT-2020 de la UIT-R) y se encuentra actualmente en las fases iniciales del proceso de normalización, supervisado por la UIT-R como IMT-2030. El marco y los objetivos generales se han definido en la recomendación UIT-R M.2160-0. Al igual que en las generaciones anteriores de arquitecturas celulares, se espera que los organismos de normalización, como el 3GPP y el ETSI, así como los grupos industriales, como la Alianza NGMN, desempeñen un papel fundamental en su desarrollo.

Parece probable que las redes 6G sean considerablemente más rápidas que sus predecesoras, gracias a los nuevos avances en las técnicas de modulación y codificación de la interfaz radioeléctrica, así como en las tecnologías de la capa física. Las propuestas incluyen la implantación de un modelo de conectividad ubicua, que podría abarcar accesos no celulares como el satélite y el WiFi, la prestación de servicios de localización precisos y el establecimiento de un marco para la computación de frontera distribuida (Distributed Edge Computing), que facilitaría el funcionamiento de un mayor número de redes de sensores, así como las cargas de trabajo de AR/VR e IA.

Otros objetivos son: la simplificación de la red y el aumento de la interoperabilidad, la reducción de la latencia y la mejora de la eficiencia energética. Esto facilitaría la implantación de modelos de negocio flexibles y descentralizados para las redes 6G, que pueden incluir la concesión de licencias locales de espectro, el uso compartido del espectro, el uso compartido de infraestructuras y la gestión automatizada inteligente. Se ha sugerido que podrían emplearse sistemas de aprendizaje automático e inteligencia artificial para facilitar las funciones mencionadas.

La alianza NGMN ha aconsejado que la 6G no se diseñe de manera que requiera una actualización del hardware de la infraestructura RAN 5G y que se desarrolle con el objetivo de atender las necesidades de los clientes. Esto refleja la opinión predominante en el sector sobre las implicaciones financieras del despliegue de la 5G, así como la preocupación por que determinadas aplicaciones y flujos de ingresos no hayan cumplido las expectativas. Se prevé que la 6G comience a desplegarse a principios de la década de 2030, pero, dadas estas preocupaciones, aún no está claro a qué características y mejoras se dará prioridad.

### **2.1.8 Banda Ultra Ancha (UWB)**

La banda ultra ancha (UWB, ultra wideband, ultra-wide band y ultraband) es una tecnología radioeléctrica que emplea un nivel mínimo de energía para la transmisión de datos en distancias cortas a gran velocidad, utilizando una parte importante del espectro radioeléctrico. La tecnología de banda ultra ancha (UWB) se ha empleado tradicionalmente en el campo de las imágenes de radar no cooperativas. Las aplicaciones más recientes se centran en la recogida de datos de sensores, en la localización precisa de objetos y en el seguimiento de estos. Los primeros casos de compatibilidad con UWB en teléfonos inteligentes se observaron en 2019.

La banda ultra ancha (UWB) es una tecnología que permite la transmisión de información a través de un amplio ancho de banda, superior a 500 MHz. Esto permite la transmisión de una cantidad sustancial de energía de señal sin incidir en la transmisión convencional de banda estrecha y onda portadora dentro de la misma banda de frecuencia. En muchos países, los límites reglamentarios permiten utilizar eficazmente el ancho de banda radioeléctrico, lo que posibilita la conectividad inalámbrica de redes de área personal (PAN) de alta velocidad de transmisión de datos, las aplicaciones de largo alcance y baja velocidad de transmisión de datos, y la coexistencia transparente de sistemas de radar y de imágenes con los sistemas de comunicaciones existentes.

Antes, el término «banda ultra ancha» se utilizaba indistintamente con el de «radio pulsada». Sin embargo, la Comisión Federal de Comunicaciones (FCC) y el Sector de Radiocomunicaciones de la Unión Internacional de Telecomunicaciones (UIT-R) han definido la UWB como una transmisión de antena para la que el ancho de banda de la señal emitida supera el menor de 500 MHz o el 20 % de la frecuencia central aritmética. Por consiguiente, los sistemas basados en impulsos, en los que cada impulso transmitido ocupa el ancho de banda de la UWB (o un agregado de al menos 500 MHz de una portadora de banda estrecha, por ejemplo, multiplexación por división ortogonal de frecuencia (OFDM)), pueden acceder al espectro de la UWB de acuerdo con la normativa pertinente.

Una diferencia clave entre las transmisiones de radio convencionales y la UWB es que los sistemas convencionales transmiten información modulando el nivel de potencia, la frecuencia o la fase (o una combinación de ellas) de una onda sinusoidal. Las transmisiones de banda ultra ancha emplean un enfoque único para la transferencia de información, según el cual la energía de radio se genera en intervalos de tiempo específicos y ocupa un gran ancho de banda. Esto permite el uso de la modulación pulso-posición o tiempo, que es una característica distintiva de la tecnología UWB. Además, la información puede modularse en señales UWB (pulsos) codificando la polaridad del pulso, su amplitud y/o utilizando pulsos ortogonales. Los pulsos UWB pueden transmitirse intermitentemente a frecuencias de pulso relativamente bajas para soportar la modulación temporal o de posición, o alternativamente, a frecuencias de hasta la inversa del ancho de banda del pulso UWB. Se ha demostrado que los sistemas Pulse-UWB funcionan a velocidades de canal superiores a 1,3 billones de pulsos por segundo utilizando un flujo continuo de pulsos UWB (Continuous Pulse UWB o C-UWB), al tiempo que soportan velocidades de transmisión de datos codificados con corrección de errores superiores a 675 Mbit/s.

Un sistema de radio UWB puede emplearse para determinar el «tiempo de vuelo» de una transmisión a varias frecuencias. Esto facilita la superación de la propagación multi trayecto, ya que algunas frecuencias siguen una trayectoria de línea de vista, mientras que las trayectorias indirectas presentan mayores retardos. Utilizando una técnica de medición bidireccional simétrica cooperativa, las distancias pueden medirse con exactitud y precisión.

## Aplicaciones

### Localización en tiempo real

La tecnología de banda ultra ancha (UWB) se emplea en sistemas de localización en tiempo real debido a su precisión y fiabilidad. Se utiliza en numerosos sectores, como la logística, la sanidad, la fabricación y el transporte. La precisión centimétrica de la UWB resulta ventajosa en contextos en los que los métodos tradicionales no son adecuados, como en el interior de edificios, donde la precisión del GPS puede ser limitada. Su bajo consumo de energía garantiza unas interferencias mínimas y permite la coexistencia con la infraestructura existente. La tecnología de banda ultra ancha (UWB) demuestra un rendimiento robusto en entornos difíciles, ya que es inmune a las interferencias multi trayecto y proporciona un posicionamiento consistente y preciso. En el campo de la logística, el uso de la tecnología UWB ha demostrado que mejora la eficiencia del seguimiento de inventarios, lo que reduce las pérdidas y optimiza los procesos operativos. En el sector sanitario, la UWB se emplea en el seguimiento de activos, la optimización del flujo de pacientes y la mejora de la coordinación asistencial. En la industria manufacturera, la UWB se utiliza para racionalizar la gestión de inventarios y mejorar la eficiencia de la producción mediante el seguimiento preciso de materiales y herramientas. La UWB también se utiliza en la planificación de rutas, la gestión de flotas y la seguridad de los vehículos en los sistemas de transporte. La UWB emplea diversas técnicas para la detección de ubicaciones, entre ellas:

- Tiempo de vuelo (ToF).
- Diferencial de tiempo de llegada (TDoA).

- Alcance bidireccional (TWR).

### **Aplicaciones Industriales**

La alta velocidad de datos y la baja latencia de la automatización y la robótica permiten la comunicación y el control en tiempo real entre máquinas y sistemas. Los protocolos de comunicación UWB garantizan una transmisión de datos fiable y segura, y permiten una coordinación y sincronización precisas de los procesos automatizados. Esto mejora la eficiencia de la fabricación, reduce los errores e incrementa la productividad global. Además, la UWB se puede integrar en sistemas robóticos para permitir la localización precisa, la detección de objetos y la evitación de colisiones, lo que mejora aún más la seguridad y la eficiencia de la automatización industrial.

La seguridad de los trabajadores y el uso de sensores de proximidad son de vital importancia en los entornos industriales. La seguridad de los trabajadores es una preocupación importante en los entornos industriales. La tecnología de banda ultra ancha (UWB) ofrece soluciones eficaces para la detección de proximidad y la seguridad de los trabajadores. El uso de dispositivos o tarjetas UWB permite controlar en tiempo real la ubicación y los movimientos de los trabajadores. Los sistemas basados en UWB pueden detectar posibles colisiones entre trabajadores y maquinaria, y emitir avisos a tiempo para evitar accidentes. Además, la tecnología UWB facilita la creación de zonas de seguridad y áreas de acceso controlado, y garantiza la interacción segura de los trabajadores con equipos peligrosos o zonas restringidas. Esto mejora la seguridad en el lugar de trabajo, reduce los accidentes y protege a los empleados de posibles peligros.

Un seguimiento y gestión de activos eficientes son cruciales para las operaciones industriales. La tecnología UWB permite realizar un seguimiento preciso y en tiempo real de los activos dentro de las instalaciones industriales. Al adherir etiquetas UWB a equipos, herramientas y existencias, las empresas pueden monitorizar su ubicación, movimiento y utilización. Esto mejora la gestión de inventario, reduce la pérdida de materiales, minimiza el tiempo de inactividad y optimiza los procesos de mantenimiento. Los sistemas de seguimiento de activos basados en UWB proporcionan datos precisos y fiables que permiten a las empresas optimizar su asignación de recursos e incrementar su eficiencia operativa global.

### **Radar**

La banda ultra ancha (UWB) ha acaparado gran atención en el campo de la tecnología de radar de apertura sintética (SAR). Debido a sus capacidades de alta resolución al utilizar frecuencias más bajas, el SAR UWB fue objeto de una amplia investigación sobre su capacidad de penetración de objetos. A principios de la década de 1990, el Laboratorio de Investigación del Ejército de Estados Unidos (ARL) desarrolló una serie de plataformas de radar de penetración terrestre, foliar y de pared, fijas y móviles. Se diseñaron para detectar e identificar artefactos explosivos improvisados enterrados y adversarios ocultos a una distancia segura. Algunos ejemplos de estos sistemas son el railSAR, el boomSAR, el radar SIRE y el radar SAFIRE. Además, el ARL ha investigado el potencial de incorporar el procesamiento Doppler a la tecnología de radar UWB con el objetivo de estimar la velocidad de un objetivo en movimiento cuando la plataforma está parada. Aunque un informe de 2013 destacaba el problema de la migración del alcance del objetivo durante el intervalo de integración al utilizar formas de

onda UWB, estudios más recientes han sugerido que las formas de onda UWB pueden ofrecer un rendimiento superior al del procesamiento Doppler convencional, siempre que se emplee un filtro adaptado adecuado.

Además, los radares Doppler de impulsos de banda ultra ancha se han empleado para la vigilancia de las constantes vitales del cuerpo humano, incluidas las señales de frecuencia cardíaca y respiratoria, así como para el análisis de la marcha humana y la detección de caídas. Representan una alternativa potencial a los sistemas de radar de onda continua, ya que ofrecen ventajas en términos de consumo de energía y perfiles de alcance de alta resolución. Sin embargo, su baja relación señal/ruido los hace vulnerables a los errores. Un ejemplo comercial de esta aplicación es RayBaby, un vigila bebés que detecta la respiración y la frecuencia cardíaca para determinar si un bebé está dormido o despierto. Raybaby tiene un alcance de detección de cinco metros y es capaz de detectar movimientos finos de menos de un milímetro.

La banda ultra ancha también se emplea en la tecnología de imágenes de radar de precisión debido a la capacidad de “see-through-the-wall” (ver a través de la pared), en la localización y seguimiento de precisión (utilizando mediciones de distancia entre puntos de marca) y en técnicas de localización de precisión basadas en el tiempo de llegada. Se ha propuesto el uso del radar UWB como sensor activo en una aplicación de reconocimiento automático de objetivos, diseñada para detectar personas u objetos caídos en las vías del metro.

### **Transferencia de datos**

Las características de la banda ultra ancha (UWB) son especialmente adecuadas para aplicaciones de corto alcance, como periféricos de ordenador personal (PC), monitores inalámbricos, videocámaras, impresión inalámbrica y transferencia de archivos a reproductores multimedia portátiles. La banda ultra ancha (UWB) se propuso para su uso en redes de área personal (PAN) y posteriormente se incluyó en el proyecto de norma PAN IEEE 802.15.3a. Sin embargo, tras un periodo de inactividad, el grupo de trabajo IEEE 802.15.3a se disolvió en 2006. El trabajo lo completaron la WiMedia Alliance y el USB Implementer Forum. La lentitud de los avances en el desarrollo de normas UWB, el coste de la implantación inicial y unas prestaciones muy inferiores a las esperadas en un principio son varias de las razones del limitado uso de la UWB en productos de consumo (lo que provocó el cese de actividades de varios proveedores de UWB en 2008 y 2009).

### **Vehículos autónomos**

La precisión de posicionamiento y alcance de la UWB permite evitar colisiones y alcanzar una precisión de localización de centímetros, superando así las capacidades de los sistemas GPS tradicionales. Además, la alta velocidad de transmisión de datos y la baja latencia permiten una comunicación fluida entre vehículos, lo que facilita el intercambio de información en tiempo real y las acciones coordinadas. Además, la UWB facilita una comunicación eficaz entre vehículos e infraestructuras, integrándose con estos para permitir un comportamiento optimizado basado en una sincronización precisa y datos sincronizados.

Por otra parte, la versatilidad de la UWB permite aplicaciones innovadoras, como las imágenes de radar de alta resolución para sistemas avanzados de asistencia al conductor, el acceso seguro sin llave mediante biometría o emparejamiento de dispositivos y los sistemas de vigilancia de ocupantes, que tienen el potencial de mejorar la comodidad, la seguridad y la protección de los pasajeros.

### 2.1.9 RFID

La tecnología RFID para sensores tiene las siguientes características:

- Es barata, y su precio disminuye con el aumento de las unidades adquiridas en los astilleros.
- Se puede fabricar con cubiertas impermeables y anti-metálicas para entornos industriales, lo que permite estar en entornos húmedos IP67 y IP68, así como no tener interferencias de lectura en entornos con muchos y variados metales.
- Pueden leerse/escribirse miles de veces sin problemas, lo que las hace reutilizables.

Debido a estas características se han desarrollado mucho y se sigue trabajando en ellos, y el mercado los empieza a incorporar en la mayoría de los usos diarios, desde tiendas para el pago en la caja, control de almacén, etc., hasta el uso profesional en oficinas para control de presencia, pagos, taquillas, etc.

Los sensores RFID se pueden clasificar por frecuencia y por si están alimentados/no alimentadas con baterías auxiliares [Roberts, 2006][Fernández-Caramés y col., 2017][Choi y Kim, 2016]. Esto es bien conocido, pero consideramos que es necesario mencionarlo brevemente para aclarar los conceptos básicos relacionados con la metodología y el hardware disponible, además, las características descritas afectan a la selección de la etiqueta RFID correspondiente para ser utilizada en entornos de almacén.

Los sensores se pueden clasificar por Frecuencia de la siguiente manera:

- *RFID de baja frecuencia (LF)*. Según la Unión Internacional de Telecomunicaciones (UIT), la banda LF va de 30 kHz a 300 kHz. La frecuencia y la potencia en esta banda no están reguladas globalmente de la misma manera: la mayoría de los sistemas funcionan a 125 kHz, pero hay algunos a 134 kHz. El rango de lectura proporcionado es corto (generalmente hasta 10 cm), por lo que, en la práctica, los dispositivos de LF no suelen ser sensibles a las interferencias de radio. Sus aplicaciones más populares son el control de accesos y la identificación de animales (principalmente mascotas y ganado).
- *RFID de alta frecuencia (HF)*. Aunque la banda HF va de 3 MHz a 30 MHz, la mayoría de los sistemas funcionan a 13,56 MHz. Los sistemas HF pueden alcanzar una distancia de lectura de hasta 1 m, lo que puede provocar interferencias y, en consecuencia, se recomiendan mecanismos de control de acceso al medio (MAC). Este tipo de sistemas RFID se utiliza masivamente en el transporte, el pago, el billeteo y el control de acceso.

- *RFID de frecuencia ultra alta (UHF)*. La banda UHF abarca en realidad de 300 MHz a 3 GHz, pero la mayoría de los sistemas operan en las bandas Industrial-Científico-Médica (ISM) en torno a 860-960 MHz y 2,45 GHz. La de 5,8 GHz se ha abandonado [Choi y Kim, 2016]. Las etiquetas UHF pueden leerse fácilmente a 10 m, por lo que son ideales para la gestión de inventarios y el seguimiento de artículos en logística.

Todos estos sensores RFID también pueden clasificarse según la forma de alimentación de las etiquetas:

- *Sistemas pasivos*. No necesitan baterías internas para funcionar, ya que rectifican la energía enviada a través de la antena del lector. Existen sistemas pasivos LF, HF y UHF, que hoy en día pueden leerse fácilmente a 10 m de distancia.
- *Sistemas activos*. Incorporan baterías, lo que les permite alcanzar mayores distancias (normalmente hasta 100 m). Debido a la normativa sobre potencia, casi todos los sistemas activos funcionan en la banda UHF.
- *Sistemas semiactivos, semi pasivos o pasivos asistidos por baterías (BAP)*. Disminuyen el consumo de energía utilizando baterías sólo para alimentar las etiquetas para determinadas funciones. Normalmente, las pilas se utilizan para alimentar la electrónica básica, mientras que la energía obtenida del lector se emplea para alimentar la interfaz de comunicaciones.

El Comité de Comunicaciones Electrónicas (ECC), en su último informe [ECC, 2021], establece en los anexos 1, 2, 11, 12 & 13 las frecuencias recomendadas para RFID, y las distingue en dos grandes grupos: frecuencias para entorno médico-sanitario (anexos 12 y 13) y frecuencias para entornos industriales (anexo 11) los otros dos anexos son recomendaciones generales sobre los dispositivos/sensores utilizados.

Las frecuencias se han dividido para evitar interferencias entre sensores cercanos. La última norma aplicada [ISO/IEC JTC 1/SC 31, 2018], establece en su parte 4, para Industrial-Scientific-Medical (ISM), una frecuencia de 2,45 GHz para trabajar con etiquetas RFID industriales.

Como resultado de estas dos normas aplicadas, en la mayoría de los países europeos, UHF se divide en:

- *Aplicaciones industriales*, 2446-2454 MHz.
- *Aplicaciones médicas*, 2483,5-2500 MHz.

Los fabricantes actuales de etiquetas RFID ofrecen para el fallo mínimo de lectura de etiquetas la HF de 13,56 MHz, que incluye el campo de la tecnología Near Field Communication (NFC). Las etiquetas pasivas basadas en esta frecuencia, permite hasta 3 m de distancia de lectura, que también es rentable para la aplicación que estamos describiendo.

NFC es un caso particular de RFID de corto alcance. Funciona en esta frecuencia, tiene un campo de lectura limitado inferior a 4 centímetros. Esta tecnología no es adecuada para aplicaciones de sensórica inalámbrica naval, excepto que sea para identificación personal mediante tarjeta o control de acceso a ciertas zonas del buque.

### 2.1.10 BLE

El Bluetooth Low Energy (también conocido como Bluetooth LE o BLE, antes comercializado como Bluetooth Smart) es una tecnología de red inalámbrica de área personal diseñada y comercializada por el Bluetooth Special Interest Group (Bluetooth SIG) para su uso en aplicaciones novedosas en los sectores de la salud, el fitness, las balizas, la seguridad y el entretenimiento doméstico. En comparación con el estándar Bluetooth original, Bluetooth Low Energy está diseñado para ofrecer un consumo de energía y un coste significativamente reducidos, manteniendo al mismo tiempo un alcance de comunicación similar. Se trata de una tecnología autónoma e independiente del estándar Bluetooth clásico, y no existe compatibilidad entre ambos. Sin embargo, Bluetooth Basic Rate/Enhanced Data Rate (BR/EDR) y LE pueden coexistir. La especificación original fue desarrollada por Nokia en 2006 con el nombre de Wibree, que posteriormente se integró en Bluetooth 4.0 en diciembre de 2009 como Bluetooth Low Energy.

El protocolo Bluetooth Low Energy (BLE) es distinto de la versión anterior, a menudo denominada Bluetooth Basic Rate/Enhanced Data Rate (BR/EDR) “clásico”. Sin embargo, ambos protocolos pueden ser compatibles con un mismo dispositivo. La especificación Bluetooth 4.0 permite a los dispositivos implementar uno o ambos sistemas, LE y BR/EDR.

La tecnología de radio Bluetooth se denomina como espectro ensanchado de difusión de frecuencia. La base de esta transmisión es la división del dato a transmitir en paquetes, los cuales viajan por los 79 canales estándar en los que se ha diseñado, de manera que cada paquete viaja por un canal. Cada canal tiene una anchura de banda de 1 MHz. Por lo general, realiza 1600 saltos por segundo con adaptación de salto frecuencia (ASF) habilitada, en inglés se llama Adaptive Frequency-Hopping (AFH). La aplicación al BLE cambia, por lo que es más simple, generando un ancho de banda de 2 MHz, lo que permite la reducción a 40 canales de transmisión.

El sistema Bluetooth Low Energy emplea las mismas radiofrecuencias de 2,4 GHz que el sistema Bluetooth clásico. Esto permite a los dispositivos de modo dual compartir una única antena de radio, pero el sistema de modulación es más sencillo como ya vimos en el capítulo de Bluetooth (2.1.7).

Bluetooth SIG identifica una serie de mercados para la tecnología de bajo consumo, especialmente en los sectores del hogar inteligente, la salud, el deporte y el fitness. Entre las ventajas citadas figuran las siguientes:

- Requiere poca energía, funciona durante largos con una pila de botón, pudiendo ser desde meses hasta años.
- Tamaño reducido y bajo coste.
- Compatibilidad con una amplia base instalada de teléfonos móviles, tabletas y ordenadores.

El Bluetooth Special Interest Group (SIG) ha definido una serie de perfiles, que son especificaciones sobre cómo debe funcionar un dispositivo en una aplicación concreta para dispositivos de baja energía, basándose en la especificación Bluetooth original. Se prevé que los fabricantes apliquen las especificaciones pertinentes a sus dispositivos para garantizar la compatibilidad. Es posible que un dispositivo contenga implementaciones de varios perfiles.

La mayoría de los perfiles actuales de aplicaciones de baja energía se basan en el perfil genérico de atributos (GATT), que es una especificación general para enviar y recibir datos breves, conocidos como atributos, a través de un enlace de baja energía. El perfil de malla Bluetooth es una excepción a esta regla, ya que se basa en el Perfil de Acceso General (GAP).

### **Perfiles de malla**

Los perfiles de malla Bluetooth utilizan Bluetooth Low Energy para comunicarse con otros dispositivos Bluetooth Low Energy de la red. Cada dispositivo puede transmitir la información a otros dispositivos Bluetooth Low Energy creando un efecto «malla». Por ejemplo, apagar las luces de todo un edificio desde un solo smartphone.

- MESH (Mesh profile): para redes de malla de base.
- MMDL (Mesh models): para definiciones de capa de aplicación. En las especificaciones de malla se utiliza el término “modelo” (model) en lugar de “perfil” (profile) para evitar ambigüedades.

### **Perfiles orientados a la salud**

Existen muchos perfiles para dispositivos Bluetooth Low Energy en aplicaciones sanitarias. El consorcio Continua Health Alliance los promueve en colaboración con Bluetooth SIG.

- BLP (Blood Pressure Profile): para la medición de la tensión arterial.
- HTP (Health Thermometer Profile): para dispositivos médicos de medición de la temperatura.
- GLP (Glucose Profile): para medidores de glucosa en sangre.
- CGMP: Perfil de medidor continuo de glucosa.

### **Perfiles para deportes y fitness**

Los perfiles para accesorios deportivos y de fitness incluyen:

- BCS: Servicio de Composición Corporal.
- CSCP (Cycling Speed and Cadence Profile): para sensores conectados a una bicicleta o una bicicleta estática para medir la cadencia y la velocidad de las ruedas.
- CPP: Perfil de potencia de ciclismo.
- HRP (Perfil de frecuencia cardiaca): para dispositivos que miden la frecuencia cardiaca.

- LNP: Perfil de localización y navegación.
- RSCP: Perfil de velocidad y cadencia de carrera.
- WSP: Perfil de báscula.

### **Sensores genéricos**

- ESP: Perfil de detección medioambiental.
- UDS: Servicio de datos de usuario.

### **Conectividad HID**

HOGP (HID over GATT Profile) que permite ratones, teclados y otros dispositivos inalámbricos con Bluetooth LE que ofrecen una batería de larga duración.

### **Detección de proximidad**

Las aplicaciones de «correa electrónica» se adaptan bien a la larga duración de la batería que permiten los dispositivos «siempre conectados». Los fabricantes de dispositivos *iBeacon* implementan las especificaciones adecuadas para que su dispositivo haga uso de las capacidades de detección de proximidad soportadas por los dispositivos iOS de Apple.

Entre los perfiles de aplicación pertinentes figuran:

- FMP (el perfil «encuéntrame» - Find Me Profile): permite que un dispositivo emita una alerta sobre un segundo dispositivo extraviado.
- PXP (el perfil de proximidad - Proximity Profile): permite a un monitor de proximidad detectar si un reportero de proximidad está dentro de un rango cercano. La proximidad física se puede estimar utilizando el valor RSSI del receptor de radio, aunque esto no tiene una calibración absoluta de las distancias. Normalmente, puede sonar una alarma cuando la distancia entre los dispositivos supera un umbral establecido.

### **Alertas y perfiles horarios**

- El perfil de estado de alerta del teléfono y el perfil de notificación de alerta permiten que un dispositivo cliente reciba notificaciones, como alertas de llamadas entrantes de otro dispositivo.
- El perfil de hora permite ajustar la hora actual y la información de la zona horaria de un dispositivo cliente desde un dispositivo servidor, como por ejemplo entre un reloj de pulsera y la hora de red de un teléfono móvil.

### **Batería**

El Servicio de Batería expone el Estado de la Batería y el Nivel de Batería de una sola batería o de un conjunto de baterías en un dispositivo.

### **Audio**

Anunciado en enero de 2020, LE Audio permite que el protocolo transmita sonido y añada funciones como que un juego de auriculares se conecte a varias fuentes de audio o que varios auriculares se conecten a una fuente, y también añade compatibilidad con audífonos. Introduce

LC3 como códec por defecto. En comparación con el audio Bluetooth estándar, ofrece una mayor duración de la batería.

En 2021 se publicaron las especificaciones sobre la implementación del Perfil de Audio Básico y la Identificación Coordinada de Conjuntos, y en marzo de 2022 el Perfil y Servicio de Audio Común.

### **Rastreo y notificación de contactos**

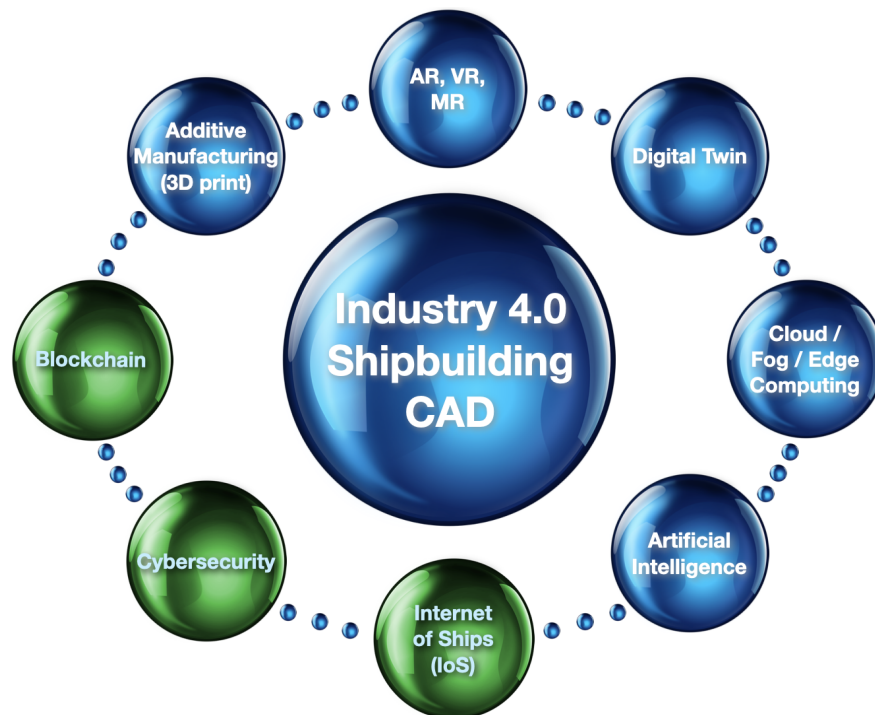
En diciembre de 2020, Bluetooth SIG publicó un borrador de especificación para un servicio de notificación de exposición para dispositivos portátiles. Este servicio permite que los servicios de notificación de exposición en dispositivos wearables se comuniquen con dispositivos cliente, como smartphones, y sean controlados por ellos.

Con todo esto hemos visto los protocolos de sensorización de elementos comunes que pueden pasar a formar parte del ecosistema de IoT que podemos tener en casa, en el que el receptor puede ser desde el móvil, elemento habitual en el uso doméstico, como otros controladores tipo PLC, para el entorno industrial.

## 2.2 Ciberseguridad

Cuando el Internet Industrial de las Cosas (IIoT) aparece en nuestra red empresarial, surge una nueva brecha de seguridad, con nuevas posibilidades, y al menos con la petición de una capa especial de ciberseguridad (CS) que se le debe aplicar. Y uno de los métodos que está creciendo en importancia debido a su simplicidad y su fuerza interior es el uso de la tecnología Blockchain (BC) como primera capa para asegurar los sensores, los datos, los actuadores y también los actores, las personas que acceden y supervisan la información IIoT desde dispositivos inteligentes, existentes en esta parte especial de nuestra red empresarial. El objetivo de este capítulo es sentar algunas de las bases de la combinación de IIoT y Blockchain para la ciberseguridad empresarial. [Benayas-Ayuso y col., 2021]

La Industria 4.0 comprende un amplio abanico de tecnologías que se integran en una única solución, fusionándose hasta el punto de que es difícil distinguir entre una y otra. Así se genera un ecosistema tecnológico completo. Partiendo de ese paradigma establecido por la Industria 4.0, la relación entre las tres tecnologías que se van a tratar es evidente. Algunas de estas tecnologías aplicadas al sector naval se muestran en la figura 2.5 [Benayas-Ayuso y col., 2021].



**Figura 2.5:** Tecnologías de la Industria 4.0 relacionadas con el IoT y la ciberseguridad [Benayas-Ayuso y col., 2021]

Una de las tecnologías más importantes de la Industria 4.0 es la ciberseguridad. Este paso no debe superarse ni tomarse como un simple paso. La ciberseguridad requiere un conjunto de capas que compliquen lo suficiente el proceso de alejamiento de los hackers junior y que no suponga un reto personal para los hackers expertos, lo suficiente como para aburrir a ambos tipos de hackers, y, al mismo tiempo, mantener las comunicaciones internas y externas disponibles y con un buen rendimiento para todos los agentes de la empresa, virtuales o reales, que trabajen en la red interna. [Benayas-Ayuso y col., 2021]

Los requisitos de seguridad, basados en la definición de N. Komminos et al., deben abordarse mediante tres conceptos principales: confidencialidad, integridad y disponibilidad, conocidos como CIA [Komminos y col., 2014]. La confidencialidad se basa en garantizar que solo los usuarios autorizados puedan leer el mensaje o acceder al servicio. La integridad se refiere a la garantía de que todo el contenido del mensaje o servicio permanezca inalterado durante la transmisión. Por último, la disponibilidad del mensaje o servicio en cualquier momento que el agente lo solicite [Dorri, Kanhere, Jurdak y Gauravaram, 2017].

La ciberseguridad en las redes distribuidas empresariales siempre es un reto, pero si añadimos el IoT a una red empresarial, el reto de la securización se convierte en una pesadilla. Sin embargo, si dividimos el trabajo en partes más pequeñas y fáciles de gestionar, el primer análisis debe hacerse diferenciando cada pequeño reto. Basándonos en el análisis de los posibles fallos de seguridad, el primer nivel de división puede ser: seguridad de la red empresarial y seguridad interna del IoT. Otro enfoque establece todos los elementos dentro de la red empresarial (intranet) como un dispositivo IoT con sus características especiales. [Benayas-Ayuso y col., 2021]

Los ataques se sufren en el entorno empresarial son (puede variar con las nuevas tecnologías) [Benayas-Ayuso y col., 2021]:

1. DDoS (Distributed Denial of Service), la red corporativa se sobrecarga, lo que ralentiza o incluso bloquea algunos procesos o controles corporativos habituales.
2. MITM (man-in-the-middle), las comunicaciones pueden ser alteradas por un atacante externo.
3. Phishing o robo de identidad mediante el robo de información clave del usuario.
4. Drive-by y su hermano, XSS (cross-site scripting).
5. Robo de contraseñas.
6. Inyección SQL, o inclusión de datos en bases de datos que no han sido generados por el sistema.
7. Espionaje pasivo o activo.
8. Ataque de cumpleaños (Birthday Attack): romper la generación de comprobaciones hash para sustituir un mensaje válido por otro no válido.
9. Malware.
10. Otros.

De esta lista se desprende que no todos los ataques son válidos para todos los tipos de dispositivos conectados a nuestra red. La idoneidad de un ataque depende del tipo de dispositivo en cuestión. Los ataques pueden ser inherentes a la tecnología de construcción del dispositivo, al proceso de fabricación, a los componentes internos o a los protocolos y puertos/vías de comunicación utilizados. [Benayas-Ayuso y col., 2021]

En las secciones siguientes se examinará la aplicabilidad de los conceptos de violación de la seguridad antes mencionados a las tres tecnologías analizadas en este documento: el Internet de las cosas (IoT), el Blockchain y la ciberseguridad. En primer lugar, esta sección describirá los problemas inherentes al Internet de los objetos (IoT), sin centrarse en ningún tipo de dispositivo específico. En segundo lugar, se examinarán las vulnerabilidades de la tecnología Blockchain en determinados escenarios. Por último, se propondrá un conjunto de soluciones para mejorar la seguridad en el ecosistema empresarial del Internet de las cosas industrial (IIoT), abordando los retos de ciberseguridad más frecuentes. [Benayas-Ayuso y col., 2021]

### 2.2.1 Problemas de ciberseguridad asociados al IoT

El uso de dispositivos conectados a la red que pueden difundir datos procedentes de fuentes diversas puede, en un principio, parecer desprovisto de problemas de seguridad inherentes. Esto se debe a que los datos en cuestión no facilitan, en sí mismos, ninguna acción dentro del ecosistema empresarial. Sin embargo, cuando los dispositivos están dotados de la capacidad de actuar de forma autónoma sobre estos datos, el potencial de riesgo se amplifica, lo que da lugar a una mayor importancia concedida al término “ciberseguridad”. [Benayas-Ayuso y col., 2021]

M. A. Khan y col. muestra de un amplio conjunto de inseguridades que se mezclan en el término “dispositivo IoT”, debido a su diferente naturaleza constructiva. Esto se refleja en el siguiente paradigma: “...the Wireless Sensor Networks (WSNs) and Machine-to-Machine (M2M) or Cyber-Physical Systems (CPS) have now evolved as integral components for the broader term IoT. Consequently, the security problems related to WSN, M2M, or CPS continue to arise in the context of IoT with the IP protocol being the main standard for connectivity” [Khan y Salah, 2018].

Las características de los dispositivos IoT incluyen heterogeneidad en cuanto a tipos de dispositivos, tecnologías de comunicación y tecnologías de conexión. Además, estos dispositivos suelen tener una seguridad integrada limitada, capacidades de hardware y software restringidas y diseños de sistemas abiertos que facilitan la integración en redes. Las limitaciones inherentes del software y el hardware de los dispositivos IoT se traducen en un bajo coste y asequibilidad, pero también en una alta susceptibilidad a las brechas de seguridad. Algunos proveedores de dispositivos IoT son conscientes de estas limitaciones y se esfuerzan por eliminarlas en sus productos. Sin embargo, esta mejora suele producirse a costa de precios más elevados, lo que dificulta su consecución en los dispositivos IoT de nuevas marcas. Además, incluso con estas mejoras, los retos persisten en los entornos empresariales. [Benayas-Ayuso y col., 2021]

A. Banafa nos muestra una amplia lista de problemas de seguridad para los dispositivos IoT [Banafa, 2017]. A esto hay que sumar los límites conocidos, que, aunque algunos se pueden superar ya en los modelos más nuevos, los problemas de seguridad más comunes de IoT se pueden resumir en los siguientes [Benayas-Ayuso y col., 2021]:

1. Sin contraseña o débil, adivinable o incluso *hardcodeada*, esto permite un fácil acceso al dispositivo y ayuda a controlarlo directamente después de un robo de contraseña.
2. Problemas de hardware que limitan la capacidad de bloquear el dispositivo frente a accesos externos no autorizados.
3. Falta de un mecanismo de actualización seguro, lo que permite ataques XSS y drive-by, en los que se sustituye alguna parte del software que se actualiza en el dispositivo o el completo por malware con el fin de realizar otro tipo de ataques como:
  - (a) Denial-of-Sleep, para agotar la batería del dispositivo.
  - (b) Denial-of-Service (DoS), en el que el dispositivo pasa a un estado de mal funcionamiento o, incluso, se utiliza para producir un Distributed Denial-of-Service (DDoS) en el sistema de datos de la empresa, mediante el incremento de los datos solicitados o enviados.
4. Sistema operativo y software embebido antiguo y sin parchear, que permite múltiples tipos de ataques, como escuchas, MITM, ataque de cumpleaños, DDoS, phishing, drive-by, XSS, malware.
5. Transferencia y almacenamiento de datos inseguros, sin control sobre los datos transmitidos, uno de los ataques más comunes es el eavesdropping.
6. Falta de conocimiento y concienciación de los usuarios, lo que nos lleva a un sistema inseguro. Se pueden aplicar todos los ataques e incluso los no enumerados.
7. Falta de hardening físico, lo que permite a un atacante externo no controlado realizar eavesdropping, ataque de cumpleaños, MITM, DDoS, phishing, drive-by, XSS y malware.
8. Los ataques de botnet, que consisten en corromper nuestra red con software no controlado, también pueden provocarnos malware y/o ataques DDoS.
9. Espionaje industrial y escuchas.
10. El highjacking de tus dispositivos IoT puede provocar ataques como el eavesdropping, el ataque de cumpleaños, MitM, DDoS, phishing, drive-by y XSS, así como malware.
11. Riesgos de integridad de datos de IoT en la seguridad en la asistencia sanitaria, que pueden conducir a ataques de espionaje y phishing.
12. Los dispositivos IoT fraudulentos permiten ataques como: escuchas, phishing, MITM, ataque de cumpleaños, XSS, malware.

Todos estos problemas ponen de manifiesto la necesidad de un enfoque unificado de la ciberseguridad en el ecosistema IoT de las redes empresariales. Es imperativo aplicar medidas sólidas para prevenir y resolver las brechas de ciberseguridad en este ámbito. Algunas tecnologías pueden ayudar a eludir la mayoría de estos problemas o, como mínimo, complicarlos. [Benayas-Ayuso y col., 2021]

Para paliar algunos de estos problemas, los sensores y actuadores se pueden agrupar en pequeños clústeres o grupos cerrados de manera que lo que se exponga sea el receptor, actuando este como un multi sensor [Benayas-Ayuso y Perez Fernandez, 2018a][Benayas-Ayuso y col., 2018]. Este tipo de agrupaciones puede continuar en la generación de mayores grupos de sensores, generando una red amplia de sensores interconectados. Este concepto está ampliamente aceptado en la industria del IoT, lo que ayuda a la integración de sistemas y separación de funciones en el entorno empresarial. A. Dorri y col. se refieren al controlador de estos clústeres más pequeños como *Cluster Head*, estableciendo un punto de referencia práctico para los entornos IoT [Dorri, Kanhere, Jurdak y Gauravaram, 2017].

## 2.2.2 Principales conceptos de Blockchain y problemas de ciberseguridad

El enfoque Blockchain se desarrolló en 1991 para asegurar la firma y el contenido de los planos de ingeniería que se compartieran a través de Internet o del correo electrónico, como método que permite al receptor comprobar que el plano no cifrado es válido y ha sido firmado por las personas registradas en él. Este método de validación requiere una gran capacidad de procesamiento, debido a la Prueba de Trabajo (POW) inherente al proceso Blockchain [Nakamoto, 2009].

Pasado un tiempo, en 2008, con la aparición del Bitcoin como criptomoneda que no requiere de un banco ni de ninguna autoridad para asegurar que las transacciones realizadas en el sistema son válidas, debido a que todo el mundo dispone de una copia de todas las transacciones realizadas en el sistema, y que impide el doble gasto de esta «moneda virtual». Este renacimiento fue posible gracias al aumento de la capacidad de procesamiento de los ordenadores y sus pequeños hermanos portátiles, los smartphones [Nakamoto, 2009].

Blockchain ofrece una plataforma en la que cualquier modificación se valida de forma múltiple, lo que supone un mayor desafío para las acciones de ruptura de seguridad y supera la interrupción de los actores no válidos (como sensores simulados) en la red. [Benayas-Ayuso y col., 2021]

Los conceptos de Blockchain principales que son requeridos para entenderlo son [Benayas-Ayuso y col., 2021]:

1. *Operación o transacción*: cada uno de los cambios realizados en los elementos gestionados por la cadena de bloques. Si está basada en criptodivisas, cada gasto de las «monedas». En nuestro caso, si está basada en dispositivos, cada petición realizada, como obtener datos, guardarlos, acceder a datos, establecer una acción, etc.

2. *Bloque*: los cambios se recogen en grupos que se denominan bloques. Contienen una cabecera con al menos lo siguiente: hash del bloque anterior, dirección del minero y hora de creación. El cuerpo incluye una lista con todas las transacciones. Se pueden añadir otros campos a la cabecera, como la versión del software, la prueba de validación y cualquier otro que añada el implementador de Blockchain.
3. *Clientes*: agentes que pueden conectarse a la Blockchain solo como espectadores, sin ninguna otra operación válida.
4. *Mineros*: son agentes con capacidad de operación, transacción y validación. Estos agentes de Blockchain realizan una doble función: crear operaciones/transacciones que se registran en un bloque y validar todos los demás bloques sugeridos por los mineros para ser añadidos a la cadena.
5. *Cadena*: colección de bloques válidos y validados.
6. *Proof-of-Work (POW)*: prueba realizada para validar el contenido de un bloque. A veces, se sustituye por una simple comprobación, dependiendo de la implementación y el alcance de la solución Blockchain. Esta comprobación se puede realizar mediante el uso de un contrato inteligente, que es una pieza de código que se ejecuta en nuestra Blockchain.
7. *Proceso de minado (proceso de validación)*: cuando un bloque está lleno, por tiempo o capacidad, se envía para ser validado por todos los mineros. Si la mayoría de los mineros responden de forma positiva, el bloque se añade a la cadena principal. En caso contrario, es rechazado y toda la información registrada en él se pierde, ya que podría tratarse de datos maliciosos o corruptos.
8. *Protocolo de consenso*: la operación de minado/validación la lanza un minero y el resto pueden aceptar o rechazar el bloque. Para no sobrecargar Blockchain, se debe adoptar algún tipo de consenso para aprobar un bloque. Si el número de mineros es bajo, se puede utilizar la Tolerancia Práctica Bizantina a Fallos, que establece un valor máximo de fallos de  $1/3$  de los mineros ( $f$ ). Si este valor se eleva y el bloque es rechazado. Por otro lado, si el valor  $(f+1)$  se eleva, el bloque se considera válido y el valor que se muestra primero establece el estado final del bloque. Para entornos con un gran número de mineros, se pueden utilizar otros protocolos de consenso.
9. *Bifurcación*: cuando se envían dos bloques válidos diferentes para su validación, se puede realizar una división de la cadena. Existen bifurcaciones suaves y bifurcaciones duras. En las primeras, ambas cadenas pueden validarse con los bloques anteriores de la cadena de bloques. Este tipo de bifurcaciones están prohibidas en las cadenas de bloques de criptomonedas. Los Hard-Forks, o bifurcaciones forzosas, se producen por un cambio en el software y, con la nueva versión, no se pueden validar los bloques anteriores de la cadena, creando dos flujos.
10. *Contrato inteligente*: la cadena de bloques de segunda generación permite crear piezas de scripting que se ejecutan en su interior, generando operaciones. Para validar el contrato, los mineros deben crear un bloque que lo incluya en su interior. Si el bloque es aprobado, el contrato inteligente comienza a funcionar. Este se ejecuta hasta que es válido para

seguir realizando sus tareas. Esta herramienta ayuda a automatizar algunas operaciones y comprobaciones. Una vez validada, esta herramienta no puede modificarse, lo que crea un método programable seguro fuera del comportamiento estándar de la cadena de bloques.

El paradigma Blockchain ayuda a que cada transacción sea única y segura, evitando la encriptación de todos los datos de la transacción; algunos pueden ser públicos y el contenido sensible puede ser encriptado, lo que lo hace válido en bruto, basado en su mecanismo. M. A. Khan y col. y X. Li y col. muestran otra vulnerabilidad en el uso de Blockchain: “Despite providing robust approaches for securing IoT, the blockchain systems are also vulnerable [Li y col., 2020].” “The consensus mechanism depending upon the miner’s hashing power can be compromised, thereby allowing the attacker to host the blockchain. Similarly, the private keys with limited randomness can be exploited to compromise the blockchain accounts. Effective mechanisms yet need to be defined to ensure the privacy of transactions and avoid race attacks which may result in double spending during transactions [Khan y Salah, 2018].”

La tecnología blockchain puede emplearse para realizar diversas funciones, como la enumeración de sensores y actuadores válidos, la inclusión de actualizaciones de software para dispositivos de red, la programación de estos dispositivos para evitar un ataque de denegación de servicio, la validación de los rangos de funcionamiento de los sensores para la transmisión de datos, la virtualización de estos dispositivos para evitar el acceso directo e incluso la creación de un historial de uso validado de medidas y acciones. El enfoque más eficaz de la ciberseguridad es la integración de todos estos métodos en una solución global. [Benayas-Ayuso y col., 2021]

### 2.2.3 Combinación de IIoT + Blockchain

Basándose en los requisitos del ecosistema IoT, hay tres tipos de ciberataques que pueden afectar significativamente a los sensores y actuadores: DDoS, MITM y eavesdropping (data sniffing). Además, existe un tipo de ataque, el ataque de cumpleaños, que puede afectar a la primera capa de seguridad si se basa en blockchain. [Benayas-Ayuso y col., 2021]

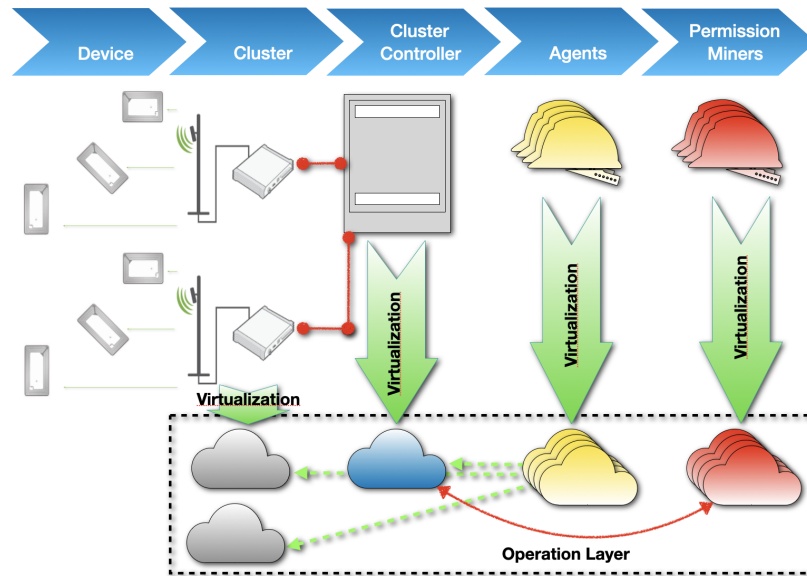
Es necesario estudiar cada problema en los dispositivos IoT para ver si blockchain puede ayudar a resolverlo [Benayas-Ayuso y col., 2021]:

1. Para *evitar el acceso directo* a los dispositivos, especialmente cuando estos son inseguros, la virtualización de estos puede ser una solución eficaz. Esta virtualización se controla a través de blockchain y solo los agentes o aplicaciones certificados pueden acceder a la red IoT virtualizada. Basándose en las investigaciones de M. Samaniego et al., en este desacoplamiento del plano de control y el plano de datos se basa un nuevo concepto basado en el Software Defined Networking (SDN), que es el Software-Defined IoT (SD-IoT) [Samaniego y Deters, 2016].
2. La *actualización de los dispositivos*, del sistema operativo o de la capa de aplicación también debe estar controlada por una capa de blockchain, lo que permite que solo las actualizaciones certificadas se incluyan en el flujo de trabajo de actualización y en el blockchain de actualización. Este concepto permite que solo los agentes certificados establezcan actualizaciones obligatorias, las programen en horas de poco trabajo y

también escalen la actualización para evitar la sobrecarga de la red si la actualización requiere una descarga enorme de paquetes de instalación o de tamaño de paquete. Los procesos de actualización mal planificados pueden provocar un ataque DDoS interno realizado por el equipo de TI de la empresa por error.

3. Blockchain también puede aplicarse a las *copias de seguridad* de cualquier dispositivo de la red, tanto virtual como real. Si los dispositivos lo permiten, puede guardarse periódicamente, registrarse y asegurarse una copia de seguridad de su estado anterior a la actualización, para restaurarla o sustituirla por una copia de su estado actual, minimizando el impacto de este evento en la red, en el caso de que la actualización falle, el dispositivo se corrompa o haya llegado al final de su vida útil.
4. La *creación de clústeres* basados en un controlador avanzado resuelve algunos de los problemas de inseguridad de los dispositivos. A través de un blockchain con un controlador de clúster, es posible conectar y desconectar dispositivos en la red. Solo los dispositivos registrados (certificados) en un controlador de clúster pueden intercambiar información con otros dispositivos de otro clúster o incluso con dispositivos del mismo clúster. La creación de clústeres solo puede incluir un dispositivo, como un móvil, que se identifica como un clúster de dispositivo único con capacidad suficiente para ejecutar algunos de los procesos de blockchain en su interior. Otros dispositivos con capacidades similares, como ordenadores portátiles o estaciones de trabajo, pueden ser considerados de la misma manera.
5. *Trazabilidad de los datos*: todas las operaciones pueden ser trazadas en una blockchain. Si, además, la blockchain tiene una cabecera de permisos que solo puede ser alterada por un agente real con los derechos correspondientes y certificada por al menos dos agentes más, la blockchain de operaciones ayuda a trazar cualquier operación que se produzca en la red. Estos agentes especiales se denominan mineros de permisos y deben ser siempre diferentes de los mineros de trazabilidad de datos. Este es el único caso en el que el cambio de parte de la cabecera de la blockchain debe abrir una nueva rama cerrando la anterior.

Esta es básicamente la primera capa de seguridad que se puede alcanzar utilizando la tecnología blockchain. La figura 2.6 ilustra todas estas características [Benayas-Ayuso y col., 2021]:



**Figura 2.6:** Construcción de una red de dispositivos IoT virtualizados [Benayas-Ayuso y col., 2021]

Algunas de sus características son [Benayas-Ayuso y col., 2021]:

- Cada capa de blockchain requiere lo siguiente: su propio POW, una generación de hash diferente y cabecera. Si se desarrolla de esta forma, un atacante malintencionado que rompa la generación de hash en una capa de blockchain no podrá afectar al resto de capas, pudiendo cerrar su relación con esta capa.
- En entornos de alta eficiencia de requisitos y alta disponibilidad, como los dispositivos IoT y el procesamiento de datos, el POW se puede sustituir por un contrato inteligente que valide el contenido de la blockchain.
- Los dispositivos no persistentes, como los smartphones, pueden utilizar un contrato inteligente para volver a autenticarse en la red blockchain, como agentes o mineros. Además, los contratos inteligentes pueden utilizarse para establecer algunas reglas y lógicas de autenticación descentralizadas que permitan la verificación única o multi parte de cualquier dispositivo IoT.
- Todos estos contratos deben ejecutarse siempre en la capa de operación, que es la representación virtualizada de la red de dispositivos IoT.

## 2.3 Inteligencia Artificial

Para la parte de análisis de datos, se ha usado ciertas técnicas de Inteligencia Artificial, lo que ha permitido realizar búsquedas no entrenadas en los datos obtenidos. Una aproximación cuantitativa, que es la opción más común o clásica, pudiera estar sesgada y limitada a una "máquina de estados finitos"(Finite State Machine - FSM), por lo que se ha descartado.

Para arrojar luz sobre esta decisión, se ha realizado un estudio de las tres formas más comunes en que afrontamos el análisis de datos en un problema complejo como este, con datos estructurados y no estructurados.

Las posibles aproximaciones al problema son: la primera opción es una metodología encapsulable en una FSM; la segunda es la evolución de la anterior, una herramienta configurable que permita hacer un estudio ad-hoc de los datos; y la tercera, que es por la que hemos optado en esta tesis, una herramienta de inteligencia artificial generativa (GenAI).

En el enfoque FSM, el analista de datos estudia el problema, ofrece una interpretación de estos basado en los resultados cuantitativos del problema y cierra la solución. Normalmente empleamos una herramienta que nos permite/ayuda en este análisis mediante la aplicación de unas reglas que establecemos a priori. Este era el antiguo enfoque tradicional. Los principales problemas de este método son [Benayas-Ayuso y col., 2024]:

1. Cada regla programada en el núcleo principal de la aplicación debe estar predefinida, funcional y técnicamente incluida.
2. Ofrece una forma rápida de comprobar, pero establece un escenario rígido para el cambio de reglas.
3. Los analistas deben contactar continuamente con los clientes (de manera eficiente y ágil) o con un equipo altamente capacitado que pueda traducir eficazmente los cambios requeridos en las reglas.  
De esta manera se puede ir mejorando el análisis, aunque queda reducido a una manera sesgada de interpretación del dato.
4. Las nuevas reglas no pueden aplicarse al modelo completo hasta que se lance la siguiente actualización de estas sobre los datos, lo que a veces también requiere reconstruir la base de datos o los archivos utilizados en el análisis.

Si quieren mejorar la solución anterior con un enfoque evolucionado, el analista debe generar una capacidad de configuración en la solución, manual o basada en una herramienta, que ayude a evolucionar las reglas durante la propia aplicación. Este es el enfoque actual de la mayoría de las herramientas de análisis de datos. Sin embargo, por lo general, este enfoque acaba saturando al analista y al propio cliente porque requiere de muchas reuniones. Además, este conjunto de reglas puede complicar la aplicación final, ya que requiere tiempo de interpretación, tiempo de aplicación y tiempo de generación de informes. Los principales problemas de este método son [Benayas-Ayuso y col., 2024]:

1. Consumo de tiempo de comprobación si se hace en fase de diseño: retraso.
2. Programación de las reglas. Pueden colisionar en los procesos de diseño.

3. Informe y aplicación de acciones automáticas. No se conocen las posibles soluciones.

La tercera vía, que es la que se ha aplicado, es la aplicación de inteligencia artificial generativa (GenAI) para el análisis de datos. Al igual que los enfoques discutidos anteriormente, algunas reglas deben definirse, pero la forma en que las definimos es en lenguaje natural, estableciendo un cambio de estado en el motor de proceso de las reglas [Benayas-Ayuso y col., 2024].

La herramienta de GenAI, que permitirá al analista auto configurar un conjunto de reglas de diseño mediante la *lectura* de las metodologías que se quieran aplicar, análisis específicos requeridos, así como normativas que permitan saber si los elementos bajo análisis están en los parámetros de esta [Benayas-Ayuso y col., 2024].

Las reglas se crean como resultado de los requisitos leídos de la normativa aplicable, y crean un conjunto de características que se aplicarán al diseño final. La aplicación de la regla puede ser fácilmente interpretada por el usuario final, que puede configurar esta característica como booleana (coincide/no coincide), como una lista de estados (lo que permite un resultado tipo máquina de estados finitos), como un número resultado de una simulación auto aplicada o incluso como un informe descriptivo de los problemas mostrados. El peso de cada característica a estudio puede normalizarse para reducir el impacto de cada una en el escenario de comprobación. Esto se puede hacer añadiendo un libro de reglas de rendimiento para los resultados del informe [Benayas-Ayuso y col., 2024].

Todo este conjunto de reglas de diseño auto configurables se aplica, como ejemplos de entrenamiento de los resultados del sistema GenAI, comprobándolos con proyectos anteriores finalizados, generando informes para ser validados por el usuario (validando la solución GenAI). Una vez que la herramienta de GenAI está entrenada y validada para realizar análisis basados en estas reglas, podemos utilizarla en la obtención de datos en tiempo real [Benayas-Ayuso y col., 2024]:

1. Aprendizaje de la evolución de la fase de diseño.
2. Aprendizaje sobre las soluciones aplicadas a los problemas descubiertos.
3. Aplicar algunas soluciones automáticas a partir de las lecciones aprendidas.
4. Crear sus propias reglas para mejorar el análisis final.

La capacidad de mejora autónoma de la solución permite reentrenar y volver a aplicar cualquier alteración de las reglas de análisis, garantizando que todos los casos del trabajo del buque se actualizan de forma coherente. Para reducir ineficiencias, este proceso de validación puede completarse cuando el buque llega a puerto y revisarse por el validador de informes y acciones del sistema correspondiente a la zona afectada por el análisis. El proceso es tan sencillo como cargar en el sistema una versión actualizada de las reglas, requisitos [Benayas-Ayuso y col., 2024].

Otra de las ventajas que permite este modelo, con la incorporación a la capacidad GenAI de un motor de cálculo proposicional, es que cada regla nueva o modificada de la Sociedad de Clasificación puede generar nuevas reglas de análisis de los datos de los sistemas de un buque, o modificar las existentes, que se pueden volver a aplicar automáticamente a los sistemas. Este proceso implica la verificación, la generación de informes, la aplicación de nuevas soluciones a

los casos existentes. Además, este enfoque facilita la evaluación de las implicaciones financieras asociadas a la aplicación de una nueva norma, solicitud de elementos y equipos que deban ser sustituidos, etc. [Benayas-Ayuso y col., 2024]

Este último enfoque no es evidente y requiere un esfuerzo adicional por parte del analista, ya que incluye algunas de las ventajas de la segunda solución, aplicándola sin esfuerzo y disminuyendo los problemas abrumadores asociados a ella. [Benayas-Ayuso y col., 2024]

Ahora se enumeran las distintas metodologías que se han aplicado al modelo de la GenAI que se propone en este estudio.

### 2.3.1 Natural Language Processing

El campo de la inteligencia artificial basado en el procesamiento del lenguaje humano para comunicación entre la persona y el ordenador se ha desarrollado la técnica que se llama Procesado del Lenguaje Natural o, en inglés, Natural Language Processing (NLP). Esta técnica es la base de las IAs generativas, ya que permite el intercambio de ideas entre la persona y la máquina de una manera natural.

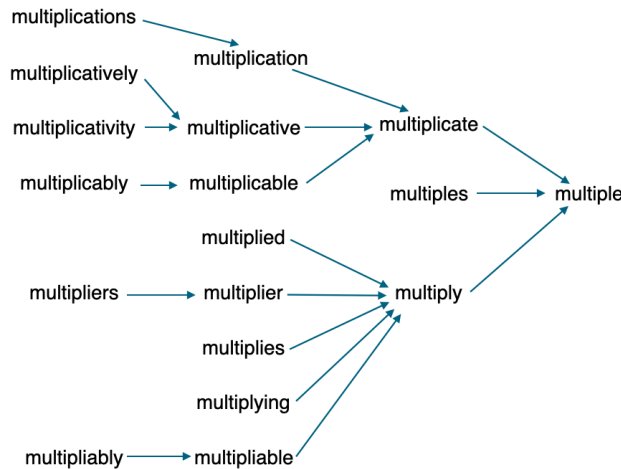
Con estas herramientas podemos hacer:

- Buscadores inteligentes no basados en palabras clave.
- Traductores con gran calidad, pues no interpretan palabras sino ideas.
- Categorizaciones automáticas de la información.
- Conversación inteligente (chat bots).
- Corrección de errores en la escritura, no solo faltas de ortografía sino de gramática o semántica.
- Análisis de entonación e intención, lo que permite saber si un texto es positivo, neutro o negativo.
- Otras aplicaciones. Este campo está creciendo mucho debido a las capacidades que implica a nivel usabilidad de las herramientas.

Como la parte limitante, en todo desarrollo de integración hombre-máquina, la interfaz de comunicación o interfaz de usuario representa el mayor reto. Hay dos siglas que representan esta tendencia, UX o experiencia de usuario, y UI o interfaz de usuario. Hay estudios específicos para poder combinar ambas de una manera eficaz. Sin embargo, al incorporar esta técnica como base de la propia herramienta o marco de trabajo, se simplifica mucho la transmisión de necesidades al sistema, ya que esta se puede hacer de una manera mucho más cercana al usuario, pudiendo mantener interfaces ordenadas por grupos de necesidades y por secuencias, que es más cercano al usuario.

Esta rama estudia la manera de dividir el mensaje humano en trozos de información entendibles por la máquina, usando técnicas de:

- *Tokenización* o división de los textos en las distintas partes (Corpus → Documentos → Párrafos → Frases → Palabras).
- *Stemming* u obtención de la raíz de las palabras basados en unos diccionarios de filtros específicos para prefijo y sufijo. En esta metodología, todas las palabras se componen de: (prefijo) + raíz + (sufijo), ambos están entre paréntesis porque no son obligatorios. Si el diccionario de prefijos/sufijos no es muy acertado, se pueden producir errores o palabras que no existen en el lenguaje hablado.
- *Lemmatization* u obtención de la raíz de las palabras basadas en un diccionario de árbol que las relaciona [ver figura 2.7]. Esta metodología es mucho más rica que el *stemming*, ya que depende sólo de la capacidad del diccionario.



**Figura 2.7:** Ejemplo de árbol de palabras para obtención de la raíz de significado

- *Part Of Speech Tag (POS TAG)* o etiqueta de tipología de palabra. Esta técnica permite identificar los distintos tipos de palabras. Este concepto es muy útil para la técnica anterior, ya que permite identificar el uso de la palabra, por ejemplo, el gerundio de un verbo puede indicar acción presente (simple) o pasada (compuesto), pero también puede usarse en forma de adverbio, por lo que puede indicar valor temporal, modal, causal, final, concesivo o condicional.



**Figura 2.8:** Ejemplo de marcado de tipología de palabras

- *Named Entity Recognition (NER)* o identificación de la clase de la palabra. Esta técnica permite encontrar nombres dentro de las categorías: Persona, Organización, Localización, Instalación/Edificación, Entidad Geopolítica o Grupo Geo-Sociopolítico. De esta manera, cuando hay denominaciones compuestas como "La Casa Rosada." "La Casa Blanca"(The

White House), que son edificaciones que representa el poder, la primera en Argentina y la segunda en Estados Unidos, se evita la clasificación errónea, ya que este *grupo nominal*, que en principio estaría compuesto por DETERMINANTE + NOMBRE + ADJETIVO, debe ser considerado como un *grupo nominal único*, en el cual todas sus palabras actúan como NOMBRE, porque es el *nombre* de la *edificación*. Esta técnica debe usarse en consonancia con la siguiente, que es el *Chunking*.




Figura 2.9: Ejemplo de marcado de clase de palabra

- *Chunking* o división sintáctica de las frases, lo que permite un análisis de las piezas de la comunicación de manera que los conceptos puedan ser clasificados, por lo tanto, entendidos, por la máquina que debe “leer” u “oír” la petición del usuario. Se suelen clasificar cada sentencia en cada una de sus piezas del puzle gramatical y sintáctico, teniendo como piezas principales los grupos nominales y los verbos, así como las palabras vínculo de partes de la frase.

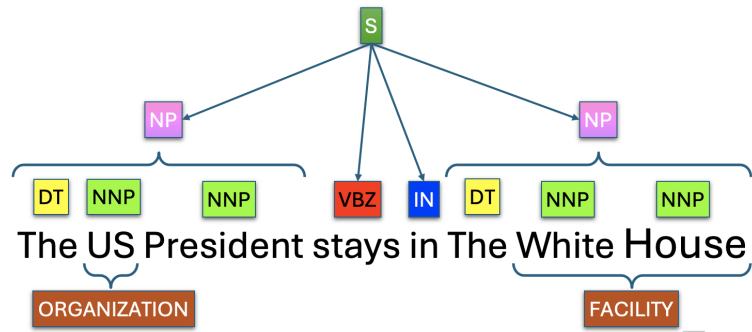


Figura 2.10: Ejemplo de puzle de palabras

- *Word Bagging* o agrupación de las palabras en un diccionario único sin repeticiones. Esta técnica permite al usuario, eliminando las palabras comunes o *Stopwords*, que representan elementos repetidos que no aportan significado, pero si ritmo, generar una lista de palabras únicas basadas en un texto o conjunto de estos.

Una vez que tenemos este diccionario, usando otros tipos de técnicas que describiremos a posteriori, se genera una serie de vectores de uso, de manera que cada vector sirve para identificar palabras similares. Además, si nosotros clasificamos nuestros párrafos en grupos específicos o categorías, nos permite clasificar cualquier tipo de texto nuevo que añadamos.

El NLP representa un conjunto de técnicas que, para poder ser útiles necesitan de otras metodologías como el aprendizaje profundo para poder desarrollar todo su potencial. Debido a esto se ha combinado con estas metodologías en este estudio.

### 2.3.2 Deep Learning

Dentro de las técnicas de inteligencia artificial para el aprendizaje de máquina destacan el aprendizaje profundo o *Deep Learning*. Este es un subconjunto de métodos de aprendizaje automático que utilizan redes neuronales para el aprendizaje de las características de un tipo de dato mediante una representación de distribución de pesos. Este campo toma inspiración de la neurociencia biológica y se centra en realizar capas de neuronas y entrenarlas para que aprendan a procesar los datos en estudio. Se le añade la característica de *profundo* porque se hace con un mínimo de tres capas hasta varias cientos o miles de ellas formando una red.

Las redes neuronales se pueden clasificar como:

- **Supervisadas:** El aprendizaje supervisado o *Supervised Learning (LS)* es una metodología del aprendizaje automático en el que se entrena un modelo mediante el uso de los objetos de entrada y un conjunto de valores de salida deseado, también referido como señal de supervisión etiquetada o, más simple, dato etiquetado. Los datos de entrenamiento se procesan para construir una función que mapea los nuevos datos con los valores de salida esperados [*Foundations of Machine Learning*, 2018]. En un escenario óptimo, el algoritmo podrá determinar correctamente los valores de salida para instancias no vistas. Esto requiere que el algoritmo de aprendizaje generalice a partir de los datos de entrenamiento a situaciones no vistas de una manera correcta. Las desviaciones que se pueden producir es por las suposiciones que el entrenador del algoritmo haga. A estas suposiciones o valores inducidos se les conoce como *sesgo inductivo* o *sesgo del aprendizaje*. Si hacemos un estudio estocástico de la capacidad de acierto, la resultante de calidad estadística de un algoritmo se mide a través del denominado *error de generalización*.
- **No Supervisadas:** El aprendizaje no supervisado es un marco del aprendizaje automático en el que, a diferencia del aprendizaje supervisado, los algoritmos aprenden patrones exclusivamente a partir de datos no etiquetados, es decir, no se ha supervisado el resultado.

El aprendizaje no supervisado se puede dividir en datos, entrenamiento, algoritmo y aplicación final del resultado. Por lo general, el conjunto de datos se obtiene en el entorno de trabajo, como un laboratorio, documentos, corpus de texto masivo obtenido mediante rastreo web, etc. Si lo comparamos con el aprendizaje supervisado, requiere muchos menos recursos, por lo que resulta más sencillo de implementar, ya que, una vez que lo lanzamos, nos podemos desentender de él.

Se han diseñado algoritmos específicamente para el aprendizaje no supervisado, como los algoritmos de agrupación, como las agrupaciones en K grupos (k-means); las técnicas de reducción dimensional, como el Análisis de Componentes Principales o Principal Component Analysis (PCA); el Aprendizaje Automático de Boltzmann (Boltzmann Machine Learning), y los autocodificadores (Autoencoders). Tras el auge del aprendizaje profundo, la mayor parte del aprendizaje no supervisado a gran escala se ha realizado mediante el entrenamiento de arquitecturas de redes neuronales de propósito general por Descenso de Gradiente (Gradient Descendant), adaptadas para realizar aprendizaje no supervisado mediante el diseño de un procedimiento de entrenamiento adecuado.

A veces, un modelo entrenado puede utilizarse tal cual, pero lo más frecuente es que se modifique para aplicaciones posteriores. Por ejemplo, el método de preentrenamiento generativo entrena un modelo para generar un conjunto de datos textuales, antes de afinarlo para otras aplicaciones, como la clasificación de textos. Como otro ejemplo, los autocodificadores se entrenan para obtener buenas características, que luego pueden utilizarse como módulo o pieza de otros modelos, como en un modelo de difusión latente.

- **Supervisión Débil:** La supervisión débil o *Weak Supervision* es una metodología del aprendizaje automático cuya relevancia y notoriedad aumentaron con la aparición de los grandes modelos lingüísticos debido a la gran cantidad de datos necesarios para entrenarlos. Se caracteriza por utilizar una combinación de una pequeña cantidad de datos etiquetados, utilizados exclusivamente en la parte del aprendizaje supervisado, que es más costoso tiempo y recursos; seguido de una gran cantidad de datos sin etiquetar, utilizados exclusivamente en la parte del aprendizaje no supervisado. En otras palabras, los valores de salida deseados solo se proporcionan para un subconjunto de los datos de entrenamiento. El resto de los datos no están etiquetados o lo están de forma imprecisa.

Intuitivamente, pueden verse como un examen y los datos etiquetados como problemas de muestra que el profesor resuelve para la clase como ayuda para resolver otro conjunto de problemas. En el marco transductivo, estos problemas sin resolver actúan como preguntas de examen. En el entorno inductivo, se convierten en problemas de práctica del tipo que formarán parte del examen.

Técnicamente, podría considerarse como la realización de agrupaciones y, a continuación, el etiquetado de las agrupaciones con los datos ya etiquetados, haciendo que la decisión se tome lejos de los conjuntos de datos con alta densidad, o la composición de una salida unidimensional del dato subyacente que marca el punto de referencia de este.

- **Redes neuronales de avance (Feedforward Neural Network - FNN):** Las redes neuronales de avance, uno de los tipos más simples de redes neuronales artificiales, son esenciales en el aprendizaje profundo y la inteligencia artificial por su arquitectura de red neuronal directa.

Las redes de avance se consideran simples porque no reciclan información, ya que carecen de las conexiones de retroalimentación que se encuentran en las redes neuronales recurrentes y las redes neuronales convolucionales.

Estas redes constan de varias capas: una capa de entrada para recibir los datos, capas ocultas con neuronas artificiales y funciones de activación para procesarlos, y una capa de salida para la decisión o predicción final.

Las redes neuronales de avance se utilizan sobre todo en el reconocimiento de patrones, la clasificación de imágenes y otras tareas de aprendizaje automático en las que no es necesario el procesamiento secuencial de datos, sino que se basan en un flujo directo de información de la entrada a la salida.

- **Perceptrón multicapa (Multilayer Perceptron - MLP):** Un perceptrón multicapa es un tipo de red neuronal de alimentación directa que consta de al menos tres capas: una capa de entrada, varias capas ocultas y una capa de salida.

Con neuronas artificiales interconectadas con funciones de activación no lineales, los MLP destacan en tareas de aproximación de funciones complejas, reconocimiento de patrones y clasificación binaria, lo que los convierte en fundamentales en tareas de aprendizaje supervisado.

A diferencia de las redes neuronales recurrentes o convolucionales, que están especializadas en el procesamiento secuencial de datos o imágenes, respectivamente, los perceptrones multicapa son redes neuronales profundas versátiles ideales para un amplio espectro de aplicaciones, desde el procesamiento del lenguaje natural hasta tareas de visión por ordenador.

Su capacidad para aprender directamente de los datos de entrada mediante retropropagación y adaptar sus parámetros internos las convierte en potentes herramientas tanto en algoritmos tradicionales de aprendizaje automático como en algoritmos más avanzados de aprendizaje profundo.

- **Red neuronal de función de base radial (Radial Basis Function Neural Network - RBFNN):** La red neuronal de función de base radial es un tipo único de red neuronal artificial que se centra principalmente en la aproximación de funciones.

Está estructurada con una capa de entrada, una capa oculta con funciones de base radial como funciones de activación y una capa de salida.

A diferencia de otras redes neuronales, las RBFNN son especialmente aptas para resolver problemas que requieren la asignación de entradas a salidas a través de una función no lineal, lo que las hace excelentes para tareas de reconocimiento de patrones e interpolación.

Esta capacidad se debe a su diseño para aproximar cualquier función suave.

Las RBFNN son muy adecuadas para aplicaciones que implican la aproximación de funciones, el reconocimiento de patrones en el aprendizaje automático y situaciones en las que la relación entre los datos de entrada y de salida debe modelarse con precisión, aprovechando su sistema adaptativo para ajustar la respuesta a los datos de entrada.

- **Red neuronal convolucional (Convolutional Neural network -CNN):** Las redes neuronales convolucionales se utilizan principalmente para el procesamiento de imágenes y se inspiraron originalmente en la organización de la corteza visual del cerebro humano.

Lo que distingue a las redes neuronales convolucionales es su arquitectura única: utilizan capas convolucionales, capas de agrupamiento y capas totalmente conectadas, todas ellas diseñadas para aprender de forma automática y adaptativa jerarquías espaciales de características a partir de las entradas. En pocas palabras, las CNN son como buscadores automáticos de patrones.

Imagine que intenta identificar un perro en una foto. Una CNN empieza reconociendo formas y texturas sencillas (líneas, curvas, etc.), luego las ensambla en patrones más complejos (orejas, ojos, etc.) y finalmente las combina en una representación de alto nivel de un perro.

Las CNN son especialmente buenas para comprender la estructura espacial de los datos, lo que las hace ideales para tareas como el reconocimiento facial. Las redes neuronales tradicionales pueden tener problemas para reconocer una cara girada hacia un lado, pero una CNN puede aprender a entender el patrón de la “cara” independientemente de su orientación o posición.

- **Red neuronal recurrente (Recurrent Neural Network - RNN):** Una red neuronal recurrente es un tipo de red neuronal diseñada para reconocer patrones en secuencias de datos, como texto, voz o datos de series temporales.

La característica más destacada de las RNN es su “memoria”: tienen en cuenta la información de pasos anteriores en su procesamiento, a diferencia de otras redes neuronales que tratan cada entrada de forma independiente.

Imaginemos las RNN como personas que leen un libro: recuerdan lo que han leído antes y utilizan ese contexto para entender lo que están leyendo en ese momento. Esta memoria hace que las RNN sean ideales para tareas de procesamiento del lenguaje natural.

La naturaleza secuencial de las RNN las convierte en la opción ideal cuando el orden de los puntos de datos es importante, como en la predicción de series temporales, el reconocimiento del habla o cualquier otra tarea que implique datos secuenciales.

- **Memoria a corto plazo de alta capacidad (Long Short-Term Memory - LSTM):** Las redes con memoria a corto plazo de alta capacidad son un tipo de redes neuronales recurrentes que resultan especialmente adecuadas para aprender de secuencias largas de datos.

Lo que hace únicas a las LSTM es su capacidad para recordar y utilizar información de muchos pasos atrás en la secuencia, superando el problema de la “memoria a corto plazo” de las RNN básicas, que tienen dificultades con las dependencias a largo plazo debido al problema conocido como “gradientes de fuga”.

Esto hace que las LSTM sean perfectas para tareas como la generación de textos: por ejemplo, si se introduce un personaje al principio de un libro, una LSTM puede acordarse de incluir referencias a ese personaje mucho más tarde.

Cuando se trata de secuencias largas en las que el contexto de entradas anteriores es crucial, las LSTM suelen ser la mejor opción.

- **Unidades recurrentes con compuerta (Gated Recurrent Units - GRU):** Las unidades recurrentes con compuerta son un tipo de red neuronal recurrente (RNN) adecuada para secuencias o series temporales de datos, lo que las hace muy eficaces en el procesamiento del lenguaje natural, el reconocimiento del habla y otras tareas que implican datos secuenciales.

A diferencia de las RNN tradicionales, que adolecen de problemas de gradiente explosivo y evanescente, las GRU abordan estos problemas con una arquitectura de red neuronal especializada que incorpora puertas que controlan el flujo de información.

Estas puertas ayudan a retener las dependencias a largo plazo y a descartar la información

irrelevante, respectivamente, sin necesidad de múltiples capas ocultas.

Las GRU simplifican la complejidad del modelo y el gasto computacional de otra variante avanzada de RNN, la memoria a largo plazo (LSTM), al tiempo que ofrecen un rendimiento comparable.

Están especialmente indicadas para aplicaciones que requieren un aprendizaje eficiente de secuencias largas con menos parámetros, como los algoritmos de aprendizaje profundo en inteligencia artificial para tareas en las que es crucial comprender la dinámica temporal.

- **Autocodificadores (Autoencoders):** Los autocodificadores son un tipo especial de red neuronal que se utiliza para aprender representaciones eficientes de los datos de entrada, lo que se conoce como codificación, y luego reconstruir los datos a partir de estas codificaciones, lo que se conoce como decodificación. La característica única de los autocodificadores es su capacidad para comprimir los datos en una forma de dimensión inferior y luego reconstruirlos.

Los autocodificadores son como un artista que intenta simplificar un paisaje complejo en un boceto. El boceto es la versión comprimida de la escena, que captura sus características más importantes. Más tarde, el artista utiliza el boceto para recrear la escena completa.

Uno de los usos más populares de los autocodificadores es la eliminación de ruido de las imágenes. Si tenemos una imagen con ruido (como granulado o puntos aleatorios), un autocodificador puede aprender a eliminar ese ruido y reconstruir una versión más limpia de la imagen.

Los autocodificadores se eligen cuando necesitamos reducir la dimensionalidad o el ruido, o cuando queremos aprender representaciones más eficientes de nuestros datos.

- **Autocodificador variacional (Variational Autoencoder - VAE):** Los autocodificadores variacionales son un tipo de autocodificador con un giro. Mientras que los autocodificadores tradicionales pueden comprimir datos y luego reconstruirlos, los autocodificadores variacionales añaden un giro probabilístico: hacen suposiciones sobre la distribución de los datos de entrada y los utilizan para generar datos completamente nuevos que se parecen a los originales.

Piense en los autocodificadores variacionales como si un arquitecto aprendiera a dibujar casas estudiando una serie de diseños. Una vez que el arquitecto comprende bien qué es una casa, puede dibujar casas nuevas parecidas a las que ha estudiado, pero no exactamente iguales.

Los autocodificadores variacionales se utilizan para generar nuevos contenidos similares a un conjunto de aprendizaje. Por ejemplo, tras aprender de miles de imágenes de caras, un autocodificador variacional puede generar imágenes de caras nuevas y realistas que nunca se han visto antes.

Estas redes se eligen cuando necesitamos no sólo aprender de los datos, sino también generar datos nuevos y similares, como en la generación de contenidos o la simulación.

- **Redes Generativas Contrarias (Generative Adversarial Network - GAN):** Una Red Generativa Contraria es un tipo de red neuronal conocida por su capacidad para generar nuevos datos sintéticos que se asemejan a los datos reales.

La red consta de dos partes: un “generador” que crea nuevos datos, y un “discriminador” que intenta distinguir entre datos reales y sintéticos. Ambas partes compiten entre sí: el generador mejora sus creaciones en función de la información que recibe del discriminador.

Imaginemos a un falsificador que intenta crear un cuadro falso convincente, mientras un experto en arte trata de detectar la falsificación. El falsificador mejora a medida que el experto es más difícil de engañar, lo que da como resultado una falsificación cada vez mejor.

Una de las aplicaciones de las redes generativas contrarias es la creación de imágenes realistas generadas por ordenador. Por ejemplo, pueden generar imágenes realistas de paisajes, personas u objetos que en realidad no existen.

Estas redes se eligen cuando queremos crear datos nuevos y realistas a partir de una distribución aprendida, como en el arte, los juegos o la simulación.

- **Mapas autoorganizados (Self Organizing Maps):** Los mapas autoorganizativos son un tipo de red neuronal profunda artificial diseñada para realizar un aprendizaje no supervisado, reduciendo la dimensionalidad de los datos y preservando al mismo tiempo las propiedades topológicas. El aspecto único de los mapas autoorganizativos es su capacidad para crear un «mapa» en el que entradas similares se agrupan en la misma región, revelando patrones ocultos o correlaciones en los datos.

Imaginemos un bibliotecario que tiene muchos tipos distintos de libros y quiere organizarlos por temas. Un mapa autoorganizado sería como un útil asistente que lee todos los libros, identifica sus temas y los coloca en las estanterías de forma que los temas similares se encuentren cerca unos de otros.

Un caso de uso de los mapas autoorganizados es la segmentación de clientes para marketing. Al introducir datos de los clientes, la red puede agrupar a clientes similares, lo que ayuda a identificar y dirigirse a segmentos de clientes distintos.

Optamos por los mapas autoorganizativos cuando tenemos datos de alta dimensionalidad y queremos comprender la estructura o los patrones subyacentes.

- **Búsqueda de arquitectura neuronal (Neural Architecture Search - NAS):** La búsqueda de arquitectura neuronal, también conocida como NAS, es un método utilizado en el aprendizaje automático para automatizar el diseño de redes neuronales artificiales. El aspecto único de NAS es que esencialmente utiliza el aprendizaje automático para crear modelos de aprendizaje automático: dado un conjunto de datos y una tarea, los algoritmos NAS exploran posibles arquitecturas de redes neuronales y seleccionan la que mejor funciona.

Piense en NAS como en un maestro cocinero que intenta crear la mejor receta posible. El chef experimenta con varias combinaciones de ingredientes, métodos de cocción y

tiempos hasta que encuentra la receta perfecta.

Una de las aplicaciones del NAS es mejorar la eficacia de las redes neuronales. Por ejemplo, NAS podría utilizarse para diseñar una red de reconocimiento de imágenes que utilice menos recursos computacionales que los diseños existentes, lo que la haría útil para su despliegue en dispositivos con una potencia de procesamiento limitada.

Optamos por NAS cuando queremos encontrar la red más eficiente para una tarea específica sin tener que diseñar y probar manualmente innumerables modelos.

- **Redes siamesas (Siamese Networks):** Las redes siamesas son un tipo único de red neuronal, diseñadas para entender lo similares o diferentes que son dos cosas comparables. Estas redes toman dos datos de entrada y emiten una medida de similitud. El nombre “siamesas” se debe a que estas redes utilizan dos sub-redes idénticas, que comparten los mismos parámetros, para procesar las dos entradas.

Considere las redes siamesas como críticos de arte entrenados que pueden decir lo parecidos que son dos cuadros. Si les presentas dos cuadros, medirían su grado de parentesco basándose en lo que han aprendido sobre arte.

Un caso típico es el de los sistemas de verificación facial, como el desbloqueo del teléfono con la cara. La red se entrena con pares de imágenes y aprende a decir si dos imágenes son de la misma persona o no.

Las redes siamesas se eligen cuando tenemos tareas que implican comparación o verificación, como la verificación de firmas, el reconocimiento de imágenes o la detección de anomalías.

- **Transformadores (Transformers):** Los Transformadores son un tipo de arquitectura de red neuronal que fueron introducidos en el paper “Attention is All You Need” por investigadores de Google en 2017. Esta es la metodología que desarrollaron en Google para el sistema de aprendizaje del NLP Vaswani y col., 2017. El NLP es un conjunto de técnicas que, para poder ser útiles necesitan de otras metodologías como el aprendizaje profundo para poder desarrollar todo su potencial.

La singularidad de los Transformadores radica en su mecanismo de atención que sopesa la importancia de los diferentes componentes de entrada de manera diferente. Esto significa que son excelentes en la comprensión del contexto, ya que deciden en qué partes de la entrada se centran en cada paso del procesamiento.

Imagine un Transformador como un lector capaz de entender no sólo palabras sueltas, sino también cómo se relacionan entre sí y con la frase en su conjunto, lo que hace que la lectura sea más completa y consciente del contexto.

Uno de los usos más conocidos de los Transformadores es la traducción de idiomas, donde la comprensión del contexto es crucial. Por ejemplo, el servicio de traducción de Google se ha beneficiado enormemente de las arquitecturas Transformador.

Podríamos optar por utilizar Transformadores cuando tratamos con datos secuenciales en los que el contexto y las relaciones entre elementos son importantes, como en las

tareas de procesamiento del lenguaje natural o el análisis de series temporales.

- **Redes neuronales modulares (Modular Neural Network - MNN):** Las redes neuronales modulares son un tipo de red neuronal profunda en la que varias redes diferentes, cada una con su tarea específica, trabajan juntas para tomar una decisión.

Lo que hace única a esta arquitectura es su división del trabajo: en lugar de que una red lo aprenda todo, cada módulo se especializa en una parte diferente del problema, trabajando en paralelo para procesar la información.

Considere una red neuronal modular como un equipo de detectives, cada uno de ellos especializado en un aspecto distinto de la resolución de delitos, como la medicina forense, la psicología o los interrogatorios. Trabajando juntos, pueden resolver un crimen con más eficacia que cualquiera de ellos por sí solo.

Un ejemplo de uso son los sistemas complejos de toma de decisiones. Por ejemplo, un coche autónomo puede utilizar un módulo para identificar peatones, otro para reconocer señales de tráfico y otro para planificar la ruta, y todos los módulos colaboran para conducir el coche con seguridad.

Optamos por las redes neuronales modulares cuando se trata de problemas complejos que pueden descomponerse en tareas más pequeñas y manejables.

- **Modelos secuencia-a-secuencia (Sequence-to-Sequence Models):** Secuencia a secuencia es un tipo de modelo de red neuronal que convierte una secuencia de entrada en una secuencia de salida. Es único porque permite secuencias de entrada y salida de diferentes longitudes, y es muy adecuado para tareas en las que tanto la entrada como la salida son secuencias, pero no se alinean elemento a elemento.

Piénsalo como un traductor que escucha una frase entera en un idioma y luego la traduce a otro. La longitud de las frases puede variar de un idioma a otro, pero el significado global debe conservarse.

Un caso de uso de los modelos secuencia a secuencia es la traducción automática, por ejemplo del inglés al francés. En este caso, la frase en inglés es la secuencia de entrada y la frase en francés es la secuencia de salida.

Podemos optar por utilizar modelos secuencia-a-secuencia cuando tengamos tareas que impliquen el mapeo de una secuencia a otra, como en la traducción de idiomas, el reconocimiento de voz o la generación de texto.

- **Redes neuronales de correlación en cascada (Cascade-Correlation Neural Network):** Las redes neuronales de correlación en cascada son un tipo especial de red neuronal que introduce un enfoque diferente para el crecimiento de la red.

A diferencia de las redes neuronales tradicionales, que crecen cambiando los pesos, las redes de correlación en cascada crecen añadiendo nuevas capas ocultas, o “nodos”, a la red. Estos nodos se congelan después de ser añadidos, lo que permite a la red aprender representaciones complejas sin riesgo de “olvidar” lo que ha aprendido previamente.

Se puede pensar en esta red como en una empresa que empieza con un pequeño

equipo de generalistas. A medida que la empresa crece y las tareas se hacen más complejas, contrata a empleados más especializados que se centran en áreas específicas. Los primeros empleados mantienen sus conocimientos y tareas, mientras que los nuevos añaden habilidades más especializadas.

Un caso de uso podría ser en una tarea compleja de reconocimiento de patrones, donde la complejidad de los patrones puede aumentar con el tiempo.

- **Redes neuronales de retardo temporal (Time Delay Neural Networks):** Las redes neuronales de retardo temporal están diseñadas específicamente para tratar datos secuenciales en los que los patrones temporales o los retardos temporales desempeñan un papel importante.

La característica distintiva de estas redes es su línea de retardo incorporada, que recuerda la información pasada durante un cierto periodo, lo cual es esencial para reconocer patrones o tendencias en datos de series temporales.

Imaginémoslo como un crítico de cine que no sólo juzga la escena actual de una película, sino que también tiene en cuenta las escenas pasadas para comprender el argumento completo.

Un caso de uso de las redes neuronales de retardo temporal es el de los sistemas de reconocimiento de voz, en los que comprender la secuencia de sonidos es importante para identificar correctamente palabras y frases. Teniendo en cuenta los sonidos anteriores, la red puede entender mejor el sonido actual y hacer predicciones más precisas.

Optamos por las redes neuronales de retardo temporal cuando tratamos con datos de series temporales o datos secuenciales en los que la información anterior es crucial para comprender el contexto actual, como en el reconocimiento del habla o el análisis musical.

- **Redes neuronales de “creencias” profundas (Deep Belief Network - DBN):** Las redes neuronales de “creencias” profundas son un tipo de red neuronal que consta de múltiples capas de variables latentes o unidades ocultas, con conexiones entre capas pero no dentro de ellas.

Están compuesta por una serie de máquinas restringidas de Boltzmann o *Restricted Boltzmann Machine (RBM)*. Una RBM es una red neuronal artificial estocástica generativa que aprende desde las entradas obteniendo una distribución de probabilidad para el conjunto de entrenamiento. Al apilar varias de estas RBM se consigue una red profunda de aprendizaje. Se aplica en el reconocimiento de imágenes, así como el de objetos, generación de imágenes comprensión de lenguaje natural y clasificación. [Fischer y Igel, 2012]

La característica distintiva de estas redes es que pueden aprender a reconstruir probabilísticamente sus entradas y descubrir estructuras intrincadas en los datos.

Imaginemos estas redes como arqueólogos que excavan cada vez más profundamente en las capas del suelo para comprender la historia y la cultura de una civilización.

Un caso de uso de las redes profundas de creencia es el reconocimiento de imágenes,

donde pueden aprender a identificar estructuras complejas en las imágenes. Por ejemplo, pueden utilizarse para detectar caras en una imagen reconociendo patrones y estructuras que componen un rostro.

Podríamos optar por utilizar Deep Belief Networks cuando tratamos con datos complejos en los que es necesario identificar estructuras o patrones ocultos, como en el reconocimiento de imágenes, el reconocimiento del habla o el procesamiento del lenguaje natural.

- **Máquinas de estado líquido (Liquid-State Machines - LSM):** Las máquinas de estado líquido (LSM) son un tipo de red neuronal que trabaja con entradas dinámicas o dependientes del tiempo.

Estas redes mantienen un “estado líquido” de actividad, en el que el estado actual es una función de la entrada actual y del historial reciente de entradas. Esta característica permite a las LSM procesar y hacer predicciones sobre datos en los que el tiempo entre eventos es crucial.

Piense en un LSM como un estanque en el que cada entrada es como una piedra lanzada al agua. Las ondas creadas por la piedra (o la entrada) interactúan con las ondas de las piedras anteriores, creando un patrón único de ondas en la superficie.

Un caso de uso de los LSM es el reconocimiento de voz, donde la secuencia y la sincronización de los sonidos son importantes. Al recordar la historia reciente de los sonidos, la red puede entender y predecir mejor lo que se dice.

Optamos por los LSM cuando tratamos con datos dinámicos o dependientes del tiempo, como en el reconocimiento del habla o el análisis musical.

- **Redes de Hopfield (Hopfield Networks):** Las redes de Hopfield son un tipo de red neuronal recurrente diseñada para modelar la memoria asociativa. Un aspecto único de estas redes es que están totalmente conectadas y tienen pesos simétricos, lo que significa que cada neurona está conectada a todas las demás y la fuerza de las conexiones es igual en ambas direcciones.

Imagine una red de Hopfield como una pequeña ciudad en la que todo el mundo se conoce y la información fluye libremente y por igual entre sus habitantes.

Las redes de Hopfield se utilizan en tareas de reconocimiento de patrones, sobre todo las relacionadas con la memoria. Si le proporcionamos un patrón parcial o distorsionado que la red ha visto antes, puede “recordar” y reconstruir el patrón original.

Podríamos optar por utilizar las redes de Hopfield cuando nos enfrentemos a problemas de reconocimiento de patrones y recuperación de memoria, en los que el objetivo es recuperar información completa a partir de entradas parciales o ruidosas.

- **Redes de estados de eco (Echo State Networks):** Las redes de estado de eco son un tipo de red neuronal recurrente que destaca por su propiedad de “estado de eco”, lo que significa que tiene memoria a corto plazo.

Esto se debe a su estructura distintiva que incluye una capa oculta grande, fija y

generada aleatoriamente llamada reservorio. Este depósito procesa las entradas y las transforma en una dimensión superior, lo que proporciona una memoria de las entradas recientes.

Imagina una Red de Estado Eco como un cañón. Cuando gritas en él, tus palabras resuenan en las paredes durante unos instantes antes de desvanecerse, dando al cañón un breve recuerdo de tus palabras.

Las redes de estados de eco se utilizan en tareas de predicción de series temporales, como predecir la siguiente palabra de una frase o los precios futuros de las acciones basándose en tendencias pasadas. Utiliza su propiedad de estado de eco para tener en cuenta la información pasada a la hora de hacer predicciones.

Podríamos optar por las Redes de Estado Eco cuando nos enfrentemos a tareas que requieran una comprensión de dinámicas o secuencias temporales, como el procesamiento del lenguaje natural o la predicción financiera.

- **Redes neuronales recurrentes bidireccionales (Bidirectional Recurrent Neural Network):** Las redes neuronales recurrentes bidireccionales son un tipo de red neuronal diseñada para tener en cuenta tanto el contexto pasado como el futuro. Esto se consigue teniendo dos capas de neuronas que procesan las entradas en direcciones opuestas: una capa procesa la secuencia de principio a fin, mientras que la otra la procesa de fin a principio.

Imagine esta red como un lector que lee una frase tanto hacia delante como hacia atrás para comprender el contexto completo de cada palabra.

Las redes neuronales bidireccionales recurrentes se utilizan en la traducción de idiomas, donde comprender el contexto completo de una palabra (tanto las palabras que la preceden como las que la siguen) puede ayudar a traducir con más precisión.

Podríamos optar por las Redes Neuronales Recurrentes Bidireccionales cuando nos enfrentemos a tareas que requieran la comprensión del contexto completo, tanto pasado como futuro, como en la traducción de idiomas, el reconocimiento del habla o cualquier procesamiento secuencial de datos.

- **Máquinas de Boltzmann restringidas (Restricted Boltzmann Machines):** Las máquinas de Boltzmann restringidas son un tipo de red neuronal artificial conocida por su estructura de dos capas y su capacidad única de aprendizaje.

Constan de unidades visibles y ocultas, pero las conexiones sólo existen entre estas dos capas, no dentro de ellas. Esta restricción les permite aprender una distribución de probabilidad sobre las entradas, lo que las hace capaces de generar nuevas muestras similares a las entradas.

Se puede pensar en estas redes como en planificadores de fiestas que observan la lista de invitados (entradas) y las interacciones entre los invitados para planificar mejor las fiestas futuras (generar nuevas muestras).

Las máquinas de Boltzmann restringidas se utilizan en sistemas de recomendación. Por

ejemplo, pueden aprender los patrones de visualización de los usuarios en una plataforma de cine y, a continuación, generar recomendaciones para las películas que un usuario es probable que disfrute.

Podemos optar por utilizar Máquinas de Boltzmann Restringidas cuando necesitemos descubrir características ocultas en los datos o generar nuevas muestras, como en sistemas de recomendación o modelos generativos.

- **Máquinas de aprendizaje extremo (Extreme Learning Machines - ELM):** Las Máquinas de Aprendizaje Extremo (ELM) son un tipo de red neuronal única por su velocidad y simplicidad. Tienen una sola capa de nodos ocultos, y sólo los pesos que conectan estos nodos con las salidas se ajustan durante el entrenamiento, mientras que los demás se asignan aleatoriamente y se dejan intactos. Esto hace que sean excepcionalmente rápidos de entrenar.

Piense en los ELM como un pensador rápido, que toma decisiones rápidamente.

Un caso práctico son las tareas de clasificación de imágenes a gran escala, en las que el procesamiento rápido es clave. Dadas numerosas imágenes, un ELM puede clasificar rápidamente cada imagen en categorías.

Podríamos optar por los ELMs cuando tratamos con grandes conjuntos de datos donde la eficiencia computacional es crucial, y podemos tolerar una compensación en precisión por velocidad.

- **Máquinas de Turing neuronales (Neural Turing Machines):** Las máquinas de Turing neuronales combinan redes neuronales con recursos de memoria externos, como un humano que utiliza un trozo de papel mientras realiza cálculos complejos. Esto les permite almacenar y recuperar datos a lo largo del tiempo, lo que las hace excelentes para manejar tareas con dependencias a largo plazo.

Imagíneseles como contables que almacenan transacciones y las recuperan cuando las necesitan.

Un caso práctico es el aprendizaje de algoritmos, donde pueden aprender a reproducir secuencias u ordenar listas.

Podríamos optar por Máquinas de Turing Neuronales cuando necesitemos una red capaz de manejar tareas complejas con dependencias de datos a largo plazo, como el aprendizaje y la ejecución de algoritmos.

- **Redes de cápsulas (Capsule Networks):** Las redes de cápsulas son únicas porque codifican jerarquías espaciales entre características, lo que les permite mantener información detallada sobre la pose y la composición del objeto. Esto les ayuda a comprender y preservar mejor las intrincadas relaciones espaciales de una imagen.

Imaginemos estas redes como arquitectos que entienden cómo encajan las distintas partes para formar una estructura.

Un caso práctico son las tareas de reconocimiento de objetos, en las que es crucial comprender la relación entre sus partes.

Podríamos optar por las redes de cápsulas cuando se trate de tareas que requieran una comprensión más profunda de las jerarquías y relaciones espaciales, como en las tareas avanzadas de reconocimiento de imágenes.

- **Redes neuronales de espigas (Spike Neural Network - SNN):** Las redes neuronales de picos (SNN) son únicas, ya que se comunican a través de picos, o breves ráfagas de actividad eléctrica, imitando la forma en que se comunican las neuronas en el cerebro. Esto las hace muy eficientes, ya que sólo se activan cuando es necesario.

Imagine las SNN como mensajeros que sólo transmiten los mensajes importantes, conservando así la energía.

Las SNN pueden utilizarse en sistemas de detección de eventos en tiempo real, ya que reaccionan con rapidez ante cambios importantes en los datos de entrada.

Podríamos optar por las SNN cuando se trate de tareas que necesiten un procesamiento eficiente en tiempo real, especialmente cuando el consumo de energía sea una preocupación importante, como en los sistemas embebidos o en los dispositivos alimentados por baterías.

- **Redes neuronales probabilísticas (Probabilistic Neural Network):** Las redes neuronales probabilísticas son únicas por su enfoque de la toma de decisiones. En lugar de encontrar el hiperplano que mejor separa las clases, como hacen muchas redes, estiman la probabilidad de que una nueva entrada pertenezca a cada clase en función de la distancia a los ejemplos de entrenamiento.

Piense en ellos como detectives que, en lugar de centrarse en una sola pista, consideran la probabilidad de que cada sospechoso sea culpable.

Un caso práctico es el diagnóstico médico, en el que pueden predecir la probabilidad de que un paciente padezca una determinada enfermedad basándose en los síntomas.

Podríamos optar por las redes neuronales probabilísticas a la hora de manejar tareas que requieran decisiones probabilísticas, como el diagnóstico o la evaluación de riesgos.

- **Redes Neuronales Difusas (Neuro-Fuzzy Networks):** Las redes neuronales difusas combinan la interpretabilidad de los sistemas difusos con la capacidad de aprendizaje de las redes neuronales. Esto les permite manejar la incertidumbre de los datos y aprender de ellos, proporcionando un razonamiento claro para sus decisiones.

Se trata de traductores expertos que convierten razonamientos humanos (lógica difusa) en datos numéricos (redes neuronales) y viceversa.

Un caso práctico es la predicción meteorológica, donde pueden manejar la incertidumbre de los datos y proporcionar predicciones precisas.

Podríamos optar por las redes neuronales difusas cuando nos enfrentemos a tareas complejas con datos imprecisos o ruidosos, en las que es crucial encontrar un equilibrio entre interpretabilidad y capacidad de aprendizaje.


- **Redes residuales profundas (Deep Residual Networks):** Las redes residuales profundas son únicas por su capacidad de entrenar redes neuronales extremadamente profundas sin dificultad. Lo consiguen mediante conexiones de salto, o atajos, que permiten retropropagar el gradiente directamente a capas anteriores.

Imagine estas redes como excursionistas que construyen puentes sobre terrenos difíciles, facilitando el camino.

Un caso de uso son las tareas de reconocimiento de imágenes, en las que han logrado resultados óptimos explotando arquitecturas muy profundas.

Podríamos optar por las redes residuales profundas cuando nos enfrentemos a tareas que requieran redes profundas, como tareas avanzadas de reconocimiento de imágenes o del habla, en las que pueden aprender patrones complejos a partir de los datos.

- **Redes Completamente Conectadas o *Fully Connected Networks*.** Esta tipología lo que hace es que todas las neuronas tienen conexión con todas. Debido a que el número de conexiones crece de manera cuadrática con el número de neuronas, se usa en paquetes pequeños. Los pesos entre neuronas se compensan durante el entrenamiento de manera que no todos los caminos se iluminan, pero todos tienen un peso específico en la solución final. Debido a su complejidad no están siendo muy usadas.



**Figura 2.11:** Ejemplo de red completamente conectada

- **Campos de Neuronas Radiantes o *Neural Radiance Fields*.** Esta técnica intenta reconstruir imágenes 3D a partir de un muestreo 2D de las mismas. Se está utilizando en programas de fotografía y para reconstrucción de escenas sin necesidad de nubes de puntos. Como trabaja muy bien con el 3D, también se está empleado para generar nuevos contenidos visuales.
- **Redes densas (Dense Networks - DenseNet):** Las redes densas, a menudo denominadas redes totalmente conectadas, son únicas porque cada neurona de una capa está conectada a cada neurona de la capa siguiente. Este diseño garantiza que la red aprenda

una representación completa de los datos de entrada.

Imagine estas redes como detectives que examinan todas las pistas posibles para resolver un misterio.

Un caso práctico son las tareas de clasificación, en las que las redes densas pueden emplearse para aprender representaciones complejas a partir de una amplia gama de características.

Podríamos optar por redes densas en escenarios en los que es necesario tener en cuenta las relaciones entre todas las características, como en tareas complejas de clasificación o regresión.

- **Redes convolucionales dilatadas (Dilated Convolutional Networks):** Las redes convolucionales dilatadas son un tipo de red neuronal convolucional única por su campo receptivo ampliado, que se consigue introduciendo huecos en el núcleo de las capas convolucionales. Esto permite a la red incorporar un contexto más amplio sin aumentar el coste computacional ni perder resolución.

Imagine estas redes como personas que utilizan prismáticos con un campo de visión más amplio para ver objetos lejanos.

Un caso práctico es la segmentación semántica de imágenes, en la que comprender un contexto más amplio es crucial para asignar etiquetas a cada píxel.

Podríamos optar por las redes convolucionales dilatadas cuando nos enfrentemos a tareas en las que una comprensión más amplia del contexto sea beneficiosa, como en tareas de segmentación de imágenes o sonidos.

- **Redes convolucionales deformables (Deformable Convolutional Networks):** Las redes convolucionales deformables son únicas porque permiten a los filtros convolucionales adaptar su forma a los datos de entrada, en lugar de estar rígidamente definidos. Esta flexibilidad las hace especialmente aptas para manejar distorsiones y variaciones en los datos de entrada.

Imagine estas redes como guantes flexibles que se adaptan a la forma y el tamaño de la mano que los lleva puestos.

Un caso práctico son las tareas de detección de objetos, en las que éstos pueden aparecer con distintas formas y orientaciones.

Podríamos optar por las redes convolucionales deformables cuando nos enfrentemos a tareas que impliquen patrones distorsionados, variados o complejos, en las que es esencial un cierto grado de adaptabilidad y flexibilidad en la extracción de características.

- **Redes neuronales gráficas (Graph Neural Networks):** Las redes neuronales gráficas son únicas, ya que están especializadas en el procesamiento de datos estructurados como gráficos. Captan las relaciones entre puntos de datos, lo que no es posible con las redes neuronales tradicionales.

Piense en estas redes como científicos sociales que analizan las conexiones dentro de

una red social.

Un caso de uso es el análisis de redes sociales, donde pueden inferir información sobre individuos basándose en sus relaciones.

Podríamos optar por las redes neuronales gráficas cuando tratamos con datos representados como gráficos, como redes sociales, estructuras moleculares o páginas web, donde las relaciones entre puntos de datos son tan importantes como los propios puntos de datos.

Estas arquitecturas se han aplicado con éxito en campos como la visión artificial, el reconocimiento de voz, el procesamiento del lenguaje natural, la traducción automática, la bioinformática, el diseño de medicamentos, el análisis de imágenes médicas, la ciencia climática, el análisis de materiales y en juegos de mesa, donde han producido resultados comparables e, incluso, en algunos casos, superiores al rendimiento de expertos humanos. .

Sin embargo, las redes neuronales actuales no pretenden modelar la función cerebral de los organismos y, en general, se consideran modelos de baja calidad para ese fin. La mayoría de los modelos de aprendizaje profundo modernos se basan en redes neuronales multicapa, como las redes neuronales convolucionales y los transformadores, aunque también pueden incluir fórmulas proposicionales o variables latentes organizadas en capas de modelos generativos profundos, como los nodos en las redes de creencias profundas y las máquinas de Boltzmann profundas.

En esencia, el aprendizaje profundo se refiere a un tipo de algoritmo de aprendizaje automático en el que se utiliza una jerarquía de capas para transformar los datos de entrada en una representación algo más abstracta y compuesta.

Por ejemplo, en un modelo de reconocimiento de imágenes, la entrada en bruto puede ser una imagen (representada como un tensor de píxeles). La primera capa de representación puede intentar identificar formas básicas, como líneas y círculos; la segunda capa puede componer y codificar la disposición de los bordes; la tercera capa puede codificar una nariz y unos ojos; y la cuarta capa puede reconocer que la imagen contiene una cara. Importante: un proceso de aprendizaje profundo puede aprender cuáles son los atributos que hay que colocar en cada nivel de forma óptima. Antes de la inteligencia artificial, las técnicas de aprendizaje automático implicaban a menudo la ingeniería de características manual para transformar los datos en una representación más adecuada para que un algoritmo de clasificación funcionara.

En el aprendizaje profundo, los rasgos no se crean de forma manual y el modelo descubre representaciones de los rasgos útiles en los datos automáticamente. Esto no elimina la necesidad de una adaptación manual; por ejemplo, variando el número de capas y su tamaño, se pueden conseguir distintos grados de abstracción.

La palabra “profundo” en “aprendizaje profundo” se refiere al número de capas a través de las cuales se transforma el dato. Más precisamente, los sistemas de aprendizaje profundo tienen una profundidad sustancial en la ruta de asignación de crédito (CAP). El CAP es la cadena de transformaciones desde la entrada hasta la salida. Los CAP describen conexiones potenciales causales entre los datos de entrada y los resultados.

En el caso de una red neuronal feedforward, la profundidad de la CAP es la profundidad de la red y equivale al número de capas ocultas más uno (ya que la capa de salida también está parametrizada). En el caso de las redes neuronales recurrentes, en las que una señal puede propagarse por una capa más de una vez, el nivel de profundidad de la CAP es potencialmente ilimitado. No existe un umbral universalmente acordado que divida el aprendizaje superficial del profundo, pero la mayoría de los investigadores coinciden en que el aprendizaje profundo implica una profundidad de la CAP superior a dos. Se ha demostrado que un CAP de profundidad dos es un universal aproximador en el sentido de que puede emular cualquier función. Más allá de eso, más capas no mejoran la capacidad de aproximación funcional de la red. Los modelos profundos (CAP >dos) son capaces de extraer mejores características que los modelos superficiales y, por tanto, las capas adicionales ayudan a aprender dichas características de forma más efectiva.

Las arquitecturas de aprendizaje profundo se pueden construir con un método gradual y capa por capa. El aprendizaje profundo ayuda a desentrañar estas abstracciones y a identificar cuáles de ellas mejoran el rendimiento. Los algoritmos de aprendizaje profundo se pueden aplicar a tareas de aprendizaje no supervisado. Esto es una ventaja importante, ya que el volumen de datos sin etiquetar es mucho mayor que el de datos con etiquetado.

Un ejemplo de estructuras profundas que se pueden entrenar de manera no supervisada son las redes de creencias profundas. El término «deep learning» fue acuñado por Rina Dechter en 1986 para la comunidad de aprendizaje automático, y por Igor Aizenberg y su equipo en 2000 para la comunidad de redes neuronales artificiales, en el contexto de las neuronas de umbral booleano.

Aunque su historia es más aparentemente complicada. En general, las redes neurales profundas se interpretan en términos del teorema de la aproximación universal o de la inferencia probabilística. El clásico teorema de la universal aproximación se refiere a la capacidad de las redes neuronales feedforward con una sola capa oculta de tamaño finito para aproximar funciones continuas. En 1989, se publicó la primera prueba, de George Cybenko, para funciones de activación sigmoide, y se generalizó a arquitecturas feedforward multicapas en 1991, por Kurt Hornik. También se ha demostrado que el teorema de la universal aproximación se cumple para funciones de activación no acotadas, como la unidad lineal rectificadora de Kunihiko Fukushima.

El teorema de aproximación universal para las redes neurales profundas trata de la capacidad de las redes con ancho de banda limitado, pero con profundidad permitida para crecer. Z. Lu y col., [2017](#) demostraron que, si el ancho de una red neuronal profunda con activación ReLU es estrictamente mayor que la dimensión de entrada, entonces la red puede aproximar cualquier función Lebesgue integrable. Si el ancho es menor o igual que la dimensión de entrada, entonces una red neuronal profunda no es un aproximador universal.

La interpretación probabilística deriva del campo del aprendizaje automático y contempla la inferencia, así como los conceptos de optimización de entrenamiento y prueba, relacionados con la adaptación y generalización, respectivamente. Más concretamente, la interpretación probabilística considera la no linealidad de la función de activación como una distribución acumulativa. La interpretación probabilística llevó a la introducción del método de eliminación

de la información irrelevante o dropout en las redes neuronales.

Una red neuronal profunda (DNN, por sus siglas en inglés) es una red neuronal artificial con varias capas entre la entrada y la salida. Existen diferentes tipos de redes neuronales, pero todas ellas siempre consisten en los mismos componentes: neuronas, sinapsis, pesos, sesgos y funciones. Estos componentes, en su conjunto, funcionan de manera que imitan las funciones del cerebro humano y se pueden entrenar como cualquier otro algoritmo de machine learning. Por ejemplo, una red neuronal artificial (RNA) entrenada para reconocer razas de perro revisará la imagen proporcionada y calculará la probabilidad de que el animal de la imagen sea de una raza concreta. El usuario puede revisar los resultados y seleccionar qué probabilidad debe mostrar la red (por encima de un cierto umbral) y volver a proponer la etiqueta correspondiente. Cada manipulación matemática en sí se considera una capa, y las redes neurales profundas tienen muchas capas, de ahí el nombre de «redes neurales». Las redes neuronales profundas pueden modelar relaciones no lineales complejas.

Las arquitecturas de las redes neurales generan modelos composicionales en los que los objetos se expresan como composiciones jerárquicas de primitivos. Las capas adicionales permiten componer las características de las capas inferiores y, en consecuencia, representan los datos complejos con un número menor de unidades que una red neuronal similar, pero más superficial. Por ejemplo, se ha demostrado que los *polinomios multi variable dispersos* son más fáciles de aproximar con redes neurales que con redes neuronales superficiales. Las arquitecturas profundas incluyen muchas variantes de unos pocos enfoques básicos. Cada arquitectura ha tenido éxito en ámbitos específicos.

No siempre es posible comparar el rendimiento de varias arquitecturas, a menos que se hayan evaluado en los mismos conjuntos de datos.

Las DNN suelen ser redes feedforward en las que los datos fluyen desde la capa de entrada hasta la capa de salida sin volver atrás. En primer lugar, la red neuronal crea un mapa de neuronas virtuales y asigna números aleatorios (pesos iniciales) a las conexiones entre ellas. Los pesos y los datos de entrada se multiplican y devuelven una salida entre 0 y 1. Si la red no reconoce un patrón concreto de forma precisa, el algoritmo ajustará los pesos. De esta manera, el algoritmo puede hacer que ciertos parámetros sean más influyentes hasta que determine la manipulación matemática adecuada para procesar los datos.

Las redes neurales recurrentes, en las que los datos pueden fluir en cualquier dirección, se utilizan para aplicaciones como la creación de modelos lingüísticos. La memoria a largo plazo de corto plazo es particularmente efectiva para este uso.

Las redes neuronales con conmutación de largo y corto plazo se utilizan en visión artificial.

Las redes neuronales con conmutación de largo y corto plazo también se han aplicado al modelado acústico para el reconocimiento automático de voz (RAV).

## Desafíos

Al igual que ocurre con las redes neuronales artificiales, muchos problemas pueden surgir con DNN entrenados de forma naïf. Dos problemas comunes son el sobreajuste y el tiempo de computación. Las DNN son propensas a sufrir sobreajuste debido a los niveles adicionales

de abstracción, que les permiten modelar dependencias poco frecuentes en los datos de entrenamiento.

Finalmente, los datos se pueden complementar mediante métodos como el recorte y la rotación, de modo que se puedan utilizar conjuntos de entrenamiento más pequeños y reducir así las posibilidades de sobreajuste.

Las redes neurales dinámicas deben tener en cuenta muchos parámetros de entrenamiento, como el tamaño (número de capas y número de unidades por capa), la tasa de aprendizaje y los pesos iniciales. Explorar el espacio de parámetros en busca de los óptimos puede no ser viable debido al coste en tiempo y recursos computacionales. Diversas técnicas, como el batido (calcular la gradiente en varios ejemplos de entrenamiento en lugar de hacerlo en ejemplos individuales), aceleran el proceso.

Las grandes capacidades de procesamiento de muchas arquitecturas de procesamiento paralelo (como las GPU o los procesadores Intel Xeon Phi) han producido notables aceleraciones en la formación de modelos, debido a la idoneidad de estos tipos de arquitectura para las computaciones matriciales y vectoriales. Alternativamente, los ingenieros pueden buscar otros tipos de redes neuronales con algoritmos de entrenamiento más sencillos y convergentes. El CMAC (Cerebellar Model Articulation Controller) es uno de estos tipos de red neuronal.

No requiere tasas de aprendizaje ni pesos iniciales aleatorios. El proceso de entrenamiento puede garantizar su convergencia en un solo paso con un nuevo conjunto de datos y el algoritmo de entrenamiento tiene una complejidad computacional lineal con respecto al número de neuronas involucradas.

## Deep Reinforcement Learning

El aprendizaje profundo por refuerzo (deep RL) constituye un subcampo del aprendizaje automático que combina el aprendizaje por refuerzo (RL) y el aprendizaje profundo. El RL aborda el problema de un agente computacional que aprende a tomar decisiones mediante un proceso de ensayo y error. La RL profunda incorpora el aprendizaje profundo a la solución, lo que permite a los agentes tomar decisiones basadas en datos de entrada no estructurados sin necesidad de ingeniería manual del espacio de estados. Los algoritmos de RL profundo son capaces de procesar grandes cantidades de datos, como la totalidad de píxeles renderizados en un videojuego, y determinar las acciones óptimas para lograr un resultado deseado, por ejemplo, maximizar la puntuación del juego. El aprendizaje profundo por refuerzo se ha empleado en multitud de ámbitos, como la robótica, los videojuegos, el procesamiento del lenguaje natural, la visión por ordenador, la educación, el transporte, las finanzas y la sanidad.

El aprendizaje profundo es una forma de aprendizaje automático que utiliza una red neuronal para transformar un conjunto de entradas en un conjunto de salidas a través de una red neuronal artificial. Los métodos de aprendizaje profundo, que a menudo utilizan el aprendizaje supervisado con conjuntos de datos etiquetados, han demostrado que resuelven tareas que implican datos de entrada brutos complejos y de alta dimensión (como imágenes) con menos ingeniería de características manual que los métodos anteriores, lo que permite avances significativos en varios campos, como la visión por ordenador y el procesamiento del lenguaje natural. En la última década, la RL profunda ha logrado resultados notables en una serie de

problemas, desde juegos individuales y multijugador, como Go, Atari Games y Dota 2, hasta robótica.

El aprendizaje por refuerzo es un proceso en el que un agente aprende a tomar decisiones mediante ensayo y error. Este problema suele modelarse matemáticamente como un proceso de decisión de Markov (MDP), en el que en cada paso temporal un agente se encuentra en un estado  $S$ , realiza una acción  $A$ , recibe una recompensa escalar y transita al siguiente estado  $S'$  según la dinámica del entorno  $p(s'|s,a)$ . El agente intenta aprender una política ( $\pi(a|s)$ ), o mapa de observaciones a acciones, para maximizar su recompensa (suma esperada de recompensas). En el aprendizaje por refuerzo (a diferencia del control óptimo), el algoritmo solo tiene acceso a la dinámica  $p(s'|s,a)$  mediante muestreo.

En muchos problemas prácticos de decisión, los estados  $S$  del MDP son de alta dimensión (por ejemplo, imágenes de una cámara o el flujo de sensores en bruto de un robot) y no pueden resolverse mediante algoritmos tradicionales de RL. Los algoritmos de aprendizaje profundo por refuerzo utilizan el aprendizaje profundo para resolver estos MDP, a menudo representando la política ( $\pi(a|s)$ ) u otras funciones aprendidas como una red neuronal y desarrollando algoritmos especializados que funcionan bien en este entorno.

Se han desarrollado diversas técnicas para entrenar políticas de resolución de tareas mediante algoritmos de aprendizaje profundo por refuerzo. Cada una de estas técnicas tiene sus propias ventajas e inconvenientes. La distinción más fundamental entre el aprendizaje por refuerzo basado en modelos y el libre de modelos es si el algoritmo intenta aprender un modelo de la dinámica del entorno.

En los algoritmos de aprendizaje profundo por refuerzo basados en modelos, se suele estimar un modelo de la dinámica del entorno mediante aprendizaje supervisado utilizando una red neuronal. Posteriormente, las acciones se obtienen mediante la utilización de un control predictivo de modelos, empleando el modelo aprendido anteriormente. Dado que la dinámica real del entorno suele divergir de la dinámica aprendida, el agente suele replanificar sus acciones en dicho entorno. Las acciones seleccionadas pueden optimizarse utilizando métodos de Monte Carlo, como el método de entropía cruzada, o una combinación de aprendizaje de modelos con métodos libres de modelos.

A diferencia de los algoritmos de aprendizaje profundo por refuerzo basados en modelos, los algoritmos sin modelos permiten aprender una política, ( $\pi(a|s)$ ), sin necesidad de modelar explícitamente la dinámica de avance. Una política puede optimizarse para maximizar los rendimientos estimando directamente el gradiente de la política, pero este enfoque es propenso a una alta varianza, lo que lo hace poco práctico para la aproximación de funciones en RL profundo. Se han desarrollado algoritmos posteriores con el objetivo de facilitar un aprendizaje más estable y se han aplicado ampliamente en la práctica. Otra clase de algoritmos de aprendizaje profundo por refuerzo sin modelo se basa en la programación dinámica, inspirada en el aprendizaje por diferencia temporal y el aprendizaje Q. En espacios de acción discretos, estos algoritmos se basan en la programación dinámica. En espacios de acción discretos, estos algoritmos suelen aprender una red neuronal Q-función  $Q(s, a)$ , que estima los rendimientos futuros que se obtendrían tomando la acción  $A$  a partir del estado  $S$ .

En espacios continuos, estos algoritmos suelen aprender tanto una estimación de valores como

una política. El campo del aprendizaje por refuerzo profundo es un área de investigación vibrante, con numerosas vías de investigación.

### **Exploración**

Un agente de RL debe encontrar un equilibrio entre exploración y explotación. Para ello, debe decidir si proseguir con las acciones que ya han demostrado obtener grandes recompensas o explorar otras acciones con potencial para descubrir recompensas más elevadas. Los agentes de RL suelen recopilar datos mediante el uso de una política estocástica, como una distribución de Boltzmann en espacios de acción discretos o una distribución gaussiana en espacios de acción continuos, induciendo así un comportamiento de exploración fundamental.

El concepto de exploración basada en la novedad o impulsada por la curiosidad se basa en la noción de proporcionar al agente un incentivo para investigar resultados hasta ahora desconocidos con el fin de identificar las soluciones óptimas. Esto se consigue modificando la función de pérdida (o incluso la arquitectura de la red) añadiendo términos que incentiven la exploración.

Además, se puede ayudar al agente en la exploración mediante demostraciones de trayectorias exitosas o mediante el modelado de recompensas, que consiste en proporcionar al agente recompensas intermedias personalizadas. Para ello, el agente debe ajustarse a la tarea que intenta completar.

**Aprendizaje por refuerzo fuera de política:** en general, los métodos basados en funciones de valor, como el aprendizaje Q, son más apropiados para el aprendizaje fuera de política y demuestran una eficacia muestral superior. Esto se debe a la reutilización de datos, que reduce la cantidad de datos necesarios para aprender una tarea. En el otro extremo del espectro se sitúa el RL fuera de línea (o «por lotes»), que contempla la adquisición de una política a partir de un conjunto de datos fijo sin más interacción con el entorno.

El **aprendizaje por refuerzo inverso (IRL)** se refiere al proceso de inferir la función de recompensa de un agente basándose en el comportamiento observado. El aprendizaje por refuerzo inverso puede emplearse para aprender a partir de demostraciones, lo que también se conoce como aprendizaje por aprendizaje. Esto se consigue infiriendo la recompensa asociada a las acciones del demostrador y optimizando posteriormente una política con el fin de maximizar los rendimientos mediante el uso de RL. Los enfoques de aprendizaje profundo se han empleado en el contexto de diversas formas de aprendizaje por imitación y RL inversa. Esto permite comunicar al agente el objetivo deseado. La repetición retrospectiva de la experiencia es un método de RL condicionado por el objetivo que consiste en almacenar y aprender de los intentos fallidos anteriores de completar una tarea. Aunque un intento fallido puede no haber alcanzado el objetivo previsto, puede servir de lección para lograr el resultado no previsto mediante el etiquetado retrospectivo.

### **Aprendizaje por refuerzo multi agente**

Un número significativo de aplicaciones del aprendizaje por refuerzo no implican un único agente, sino un conjunto de agentes que aprenden y se adaptan juntos. Estos agentes pueden ser competitivos, como ocurre en muchos juegos, o cooperativos, como ocurre en muchos sistemas multi agente del mundo real. El campo del aprendizaje por refuerzo multi agente se

ocupa de los retos que surgen en este contexto.

La generalización es la capacidad de un sistema para funcionar correctamente con datos de entrada que no se han visto anteriormente, lo que constituye la principal ventaja de utilizar herramientas de aprendizaje profundo en el aprendizaje por refuerzo. A modo de ejemplo, las redes neuronales entrenadas para el reconocimiento de imágenes son capaces de identificar que una imagen contiene un pájaro, incluso si nunca se han encontrado previamente con esa imagen específica o incluso con ese pájaro en particular. Como la RL profunda permite utilizar datos brutos (por ejemplo, píxeles) como entrada, se reduce la necesidad de predefinir el entorno, lo que permite generalizar el modelo a múltiples aplicaciones. Con esta capa de abstracción, es posible diseñar algoritmos de aprendizaje profundo por refuerzo generalistas, y el mismo modelo puede emplearse para tareas dispares. Un método para mejorar la capacidad de generalización de las políticas entrenadas con políticas de RL profundo consiste en incorporar el aprendizaje de representación.

### 2.3.3 Variational Auto Encoder

En aprendizaje automático, un autoencoder variacional (VAE) es una arquitectura de red neuronal artificial introducida por Diederik P. Kingma y Max Welling. Pertenecce a la familia de los modelos gráficos probabilísticos y los métodos bayesianos variacionales. Además, los autocodificadores variacionales pueden examinarse dentro de la formulación matemática de los métodos bayesianos variacionales. Se trata de conectar una red de codificadores neuronales a su decodificador a través de un espacio latente probabilístico (por ejemplo, como una distribución gaussiana multivariante) que corresponde a los parámetros de una distribución variacional.

Por consiguiente, el codificador transforma cada punto de datos (por ejemplo, una imagen) de un vasto e intrincado conjunto de datos en una distribución dentro del espacio latente, en lugar de asignarle una única posición dentro de ese espacio. La función del descodificador es la inversa de la del codificador, es decir, pasar del espacio latente al espacio de entrada, de nuevo según una distribución (aunque en la práctica, en la etapa de descodificación, rara vez se añade ruido). Al asignar un punto a una distribución en lugar de a un único punto, la red puede evitar el sobreajuste de los datos de entrenamiento. Ambas redes suelen entrenarse juntas, utilizando el truco de la reparametrización, aunque la varianza del modelo de ruido puede aprenderse por separado.

Aunque este tipo de modelo se diseñó inicialmente para el aprendizaje no supervisado, su eficacia ha quedado demostrada en el aprendizaje semi supervisado y supervisado.

Un autoencoder variacional es un modelo generativo que comprende una distribución a priori y una distribución de ruido. Normalmente, estos modelos se entrenan utilizando el meta-algoritmo de maximización de expectativas, que se ejemplifica mediante PCA probabilístico, codificación dispersa (spike & slab) y otras técnicas. El esquema mencionado optimiza un límite inferior de la verosimilitud de los datos, que suele ser intratable. Para lograrlo, es necesario descubrir las distribuciones  $q$ , o variacionales posteriores. Las distribuciones  $q$  suelen parametrizarse para cada punto de datos individual en un proceso de optimización independiente. Sin embargo, los auto decodificadores variacionales emplean una red neuronal

como enfoque amortizado para optimizar conjuntamente todos los puntos de datos. La mencionada red neuronal recibe los puntos de datos como entrada y produce los parámetros de la distribución variacional como salida. Como mapea desde un espacio de entrada conocido a un espacio latente de baja dimensión, se denomina codificador.

La segunda red neuronal de este modelo es el decodificador. Es una función que mapea desde el espacio latente al espacio de entrada, por ejemplo, como las medias de la distribución de ruido. Es posible emplear una red neuronal alternativa que mapee a la varianza; sin embargo, esto puede omitirse en aras de la simplicidad. En tal caso, la varianza puede optimizarse mediante el descenso gradiente.

Para optimizar este modelo, es necesario tener en cuenta dos conceptos clave: el «error de reconstrucción» y la divergencia de Kullback-Leibler (KL-D). Ambos términos se derivan de la expresión de la energía libre del modelo probabilístico  $y$ , por lo tanto, dependen de la distribución del ruido y del supuesto a priori de los datos. Por ejemplo, en una tarea VAE típica, como la empleada en el conjunto de datos IMAGENET, se suele suponer una distribución de ruido gaussiano. Sin embargo, en tareas como MNIST binarizado, se requiere una distribución de ruido Bernoulli. La KL-D, derivada de la expresión de la energía libre, trata de maximizar la masa de probabilidad de la distribución  $q$  que se solapa con la distribución  $p$ , pero esto puede dar lugar a una distribución de modo-sexo. Esto puede dar lugar a un comportamiento de búsqueda de modos, que es una consecuencia indeseable. El término «reconstrucción» representa la parte restante de la expresión de la energía libre, que requiere una aproximación de muestreo para calcular su valor esperado.

Enfoques más recientes han consistido en sustituir la divergencia de Kullback-Leibler (KL-D) por distancias estadísticas alternativas, como se detalla en la sección siguiente, «Variantes de distancia estadística VAE».

### 2.3.4 Generative Adversarial Networks

Una red generativa adversarial (GAN) es un tipo de marco de aprendizaje automático y un marco destacado para abordar la inteligencia artificial generativa. El concepto fue desarrollado inicialmente por Ian Goodfellow y sus colegas en junio de 2014. En una GAN, dos redes neuronales compiten entre sí en forma de un juego de suma cero, en el que la ganancia de un agente supone la pérdida de otro.

La técnica es capaz de aprender a generar nuevos datos con las mismas características estadísticas que el conjunto de entrenamiento. Por ejemplo, un GAN entrenado con fotografías puede generar nuevas fotografías que, al menos visualmente, parezcan auténticas a los observadores humanos y presenten una serie de características realistas. Aunque se propusieron inicialmente como un modelo generativo para el aprendizaje no supervisado, los GAN también han demostrado su eficacia en el aprendizaje semi supervisado, el aprendizaje totalmente supervisado y el aprendizaje por refuerzo.

El concepto central de una GAN se basa en que «el entrenamiento indirecto se realiza a través del discriminador, que es otra red neuronal que evalúa el realismo percibido de la entrada. Este se actualiza dinámicamente. Por consiguiente, el generador no se entrena para minimizar la

distancia a una imagen concreta, sino para engañar al discriminador. Esto permite al modelo aprender sin supervisión.

Las GAN son análogas al mimetismo en biología evolutiva, con una carrera armamentística evolutiva entre ambas redes.

La red generativa genera candidatos, mientras que la red discriminativa los evalúa. El concurso se realiza en función de las distribuciones de datos. Típicamente, la red generativa se entrena para mapear desde un espacio latente hasta una distribución de datos de interés, mientras que la red discriminativa se encarga de distinguir entre los candidatos generados por el generador y la distribución de datos verdadera. El objetivo de la red generativa durante el entrenamiento es aumentar la tasa de error de la red discriminativa. Esto se consigue produciendo nuevos candidatos que el discriminador cree que no han sido sintetizados, introduciendo así elementos de la verdadera distribución de datos. El discriminador se entrena con un conjunto de datos conocido, que sirve como datos de entrenamiento iniciales. El proceso de entrenamiento consiste en presentar a la red muestras del conjunto de datos de entrenamiento hasta que alcance un nivel aceptable de precisión. El generador se entrena en función de su capacidad para engañar al discriminador. Normalmente, el generador se siembra con una entrada aleatoria extraída de un espacio latente predefinido (por ejemplo, una distribución normal multivariante). A continuación, el discriminador evalúa la salida del generador. Los procedimientos de retro propagación se llevan a cabo de forma independiente en ambas redes para mejorar la capacidad del generador de producir muestras superiores, al tiempo que se refuerza la capacidad del discriminador de identificar muestras sintéticas. En el contexto de la generación de imágenes, el generador suele ser una red neuronal convolucional, mientras que el discriminador suele ser una red neuronal convolucional.

Las GAN son modelos generativos implícitos, en contraste con alternativas como los modelos generativos basados en flujos, que modelan explícitamente la función de verosimilitud y proporcionan un medio para encontrar la variable latente correspondiente a una muestra dada.

En comparación con las redes de creencia totalmente visibles, como WaveNet y PixelRNN, y los modelos autorregresivos en general, las GAN son capaces de generar una sola muestra completa en una sola pasada, en lugar de requerir múltiples pasadas por la red.

A diferencia de las máquinas de Boltzmann y de los ICA lineales, no existen restricciones en la forma de la función empleada por la red.

# Capítulo 3

## Materiales y métodos

Para el desarrollo de la tesis se han empleado un conjunto de materiales físicos, así como materiales o conceptos tecnológicos que permiten generar el modelo sobre el que se basa la tesis.

La tesis pretende hacer un estudio del IoS, y más concretamente de la aplicación de este en el sector naval. Nos hemos centrado en el procesado de la señal obtenida de un sensor mediante el uso de IA, para la predicción de eventos o prevención de siniestros por el procesado de la información de un modelo de gemelo digital.

Durante el estudio se ha visto que el modelo presentado era aplicable a cualquier sensorización que se necesitase, ya sea una aplicación de estudio de sensores como la sensorización propia de un CAD para poder explotar el dato de cara a la ayuda o automatización de procesos, pruebas y tareas de usuario.

## 3.1 Materiales físicos

Para la parte del estudio de la sensórica inalámbrica se han usado los materiales físicos que se describen a continuación.

### 3.1.1 Raspberry Pi

Se ha usado una Raspberry PI con módulo de antenas. El juego de antenas se compone de tres elementos, una antena de corto alcance, una antena de medio alcance y una antena de largo alcance. La detección se ha probado con tarjetas NFC, con móviles y con etiquetas de tiendas de ropa.

Para el estudio con la antena de largo alcance, se ha guardado en una caseta metálica para generar las interferencias que se producen en un barco, cuyo ambiente siempre es metálico.

Se dejó el tiempo prudencial, tomando datos de todos los elementos que pasaban por la zona ya fueran propios de la familia o ajenos. Con estos datos intenta triangular las posiciones de los de cada uno de los elementos.

Se han sacado los datos de apantallamiento, eco y degradación de la señal, que están siendo objeto de estudio todavía, y que quedan para futuros desarrollos.

### 3.1.2 Arduino One

Se ha usado también un Arduino uno como un centro de procesamiento cercano para sensores. En este caso, el Arduino simulaba las condiciones de receptor de baja capacidad para el estudio de los clústeres de sensores y sus distintas agrupaciones.

### 3.1.3 Otros materiales

Si empleado una impresora 3D, para generar soportes para cada uno de los elementos que ha estado tomando medidas o procesándolas, a modo de centro de datos cercano.

Toda la programación que se ha tenido que desarrollar para cada una de las tarjetas de adquisición de datos que se ha empleado, ha sido realizado en lenguajes compatibles con las mismas.

En el caso de la tarjeta, Raspberry Pi, se ha usado Python, y en el caso de la Arduino, uno se ha usado C++ compilado.

## 3.2 Materiales digitales

Para el desarrollo de la investigación se han empleado los siguientes lenguajes de programación y librerías, lo que representan materiales digitales para el desarrollo del marco de trabajo a usar.

### 3.2.1 Python

Python es un lenguaje de programación interpretado, interactivo y orientado a objetos. Incorpora módulos, excepciones, tipado dinámico, tipos de datos dinámicos de muy alto nivel y clases. Además, soporta múltiples paradigmas de programación más allá de la programación orientada a objetos, como la programación procedimental y funcional. Python combina una gran potencia con una sintaxis muy clara. Dispone de interfaces para muchas llamadas al sistema y bibliotecas, así como para varios sistemas de ventanas, y es extensible en C o C++. También puede utilizarse como lenguaje de extensión para aplicaciones que necesiten una interfaz programable. Por último, Python es portátil: funciona en muchas variantes de Unix, incluidos Linux y macOS, y en Windows. [Python.org, 2024]

### 3.2.2 TensorFlow

TensorFlow es un sistema de aprendizaje automático que funciona a gran escala y en entornos heterogéneos. TensorFlow utiliza grafos de flujo de datos para representar el procesamiento computacional, el estado compartido y las operaciones que modifican dicho estado. Mapea los nodos de un grafo de flujo de datos entre muchas máquinas en un clúster y dentro de una máquina entre múltiples dispositivos computacionales, incluyendo CPUs multinúcleo, GPUs de propósito general y ASIC diseñados a medida conocidos como Tensor Processing Units (TPUs). Esta arquitectura ofrece flexibilidad al desarrollador de aplicaciones: mientras que en los diseños anteriores de «servidor de parámetros» la gestión del estado compartido está integrada en el sistema, TensorFlow permite a los desarrolladores experimentar con nuevas optimizaciones y algoritmos de entrenamiento. TensorFlow admite una gran variedad de aplicaciones, con especial atención al entrenamiento y la inferencia en redes neuronales profundas. Varios servicios de Google utilizan TensorFlow en producción, lo hemos publicado como proyecto de código abierto y se ha extendido su uso en la investigación del aprendizaje automático. [Abadi y col., 2016]

### 3.2.3 NumPy

NumPy es una biblioteca para el lenguaje de programación Python que añade soporte para matrices multidimensionales de gran tamaño, junto con una gran colección de funciones matemáticas de alto nivel para operar con estas matrices multidimensionales. [Harris y col., 2020]

NumPy sucedió a Numeric, que fue creado originalmente por Jim Hugunin con la colaboración de otros desarrolladores. En 2005, Travis Oliphant creó NumPy incorporando características del competidor Numarray en Numeric, con amplias modificaciones. NumPy es un software de

código abierto y cuenta con numerosos colaboradores. NumPy recibe financiación del proyecto NumFOCUS. [NumFocus.org, 2024]

### 3.2.4 SpaCy

Las estructuras de datos centrales de spaCy son la clase Lengua, el Vocabulario y el objeto Doc. La clase Language se utiliza para procesar un texto y convertirlo en un objeto Doc. Normalmente se almacena como una variable llamada nlp. El objeto Doc posee la secuencia de tokens y todas sus anotaciones. Al centralizar las cadenas, los vectores de palabras y los atributos léxicos en el Vocab, evitamos almacenar múltiples copias de estos datos. Esto ahorra memoria y garantiza que haya una única fuente de verdad.

Las anotaciones de texto también están diseñadas para permitir una única fuente de verdad: el objeto Doc es el propietario de los datos, y Span y Token son vistas que apuntan a él. El objeto Doc es construido por elTokenizer, y luego modificado en su lugar por los componentes del pipeline. El objeto Language coordina estos componentes. Toma el texto en bruto y lo envía a través de la cadena, devolviendo un documento anotado. También organiza la formación y la serialización.

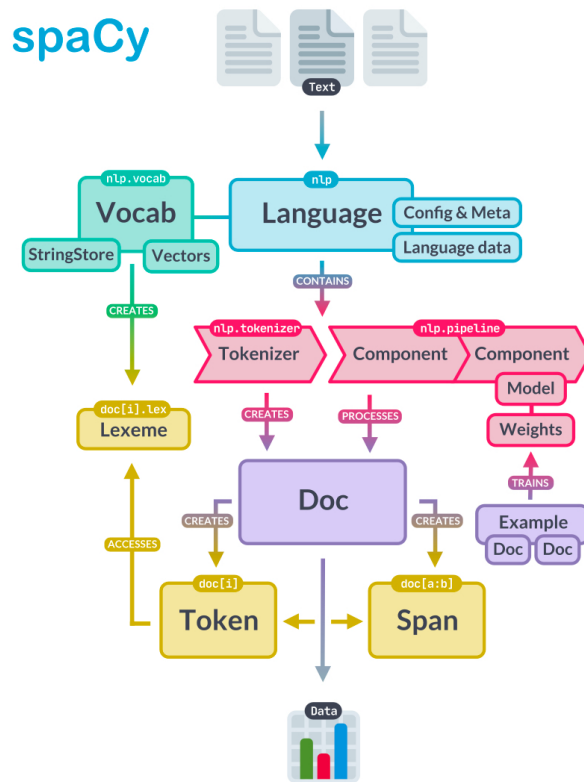


Figura 3.1: Flujo de spaCy

### 3.3 Metodología para la aplicación de la Inteligencia Artificial

Basándose en los materiales anteriores, ya sean físicos o digitales, se ha estudiado uno de los problemas base que genera, durante el diseño de un buque, mucha disrupción en las oficinas de diseño, así como durante las colaboraciones que se hacen para un diseño de un buque.

El problema está en la incapacidad que tienen las ingenierías auxiliares asociadas al proyecto del buque para diseñar de manera efectiva y poder añadir, incluso, aunque ya no es de normativa, todos los elementos del buque, con la calidad esperada por el armador.

Para ello, se ha desarrollado primero el Marco conceptual, luego se ha propuesto una solución al problema, y luego se ha diseñado el Marco de desarrollo de la solución [figura 3.2]

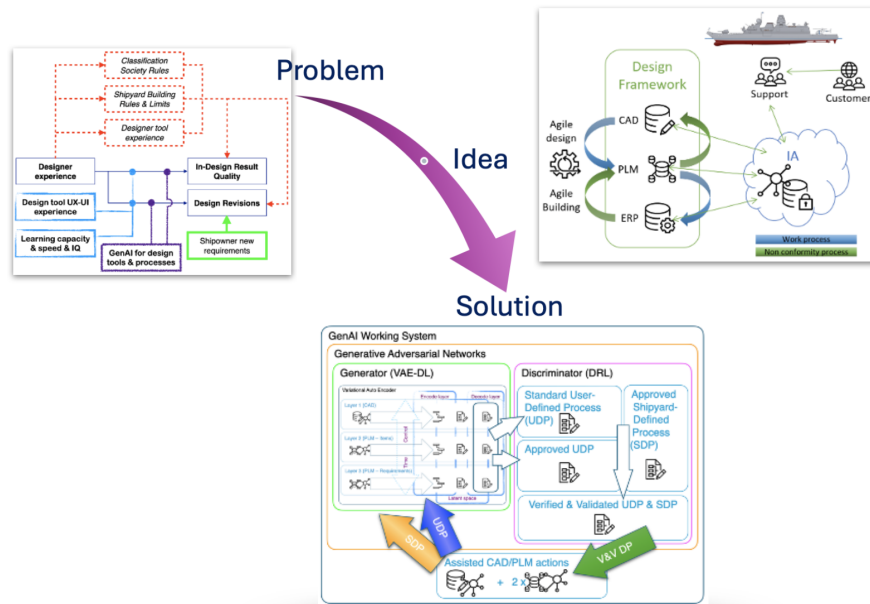
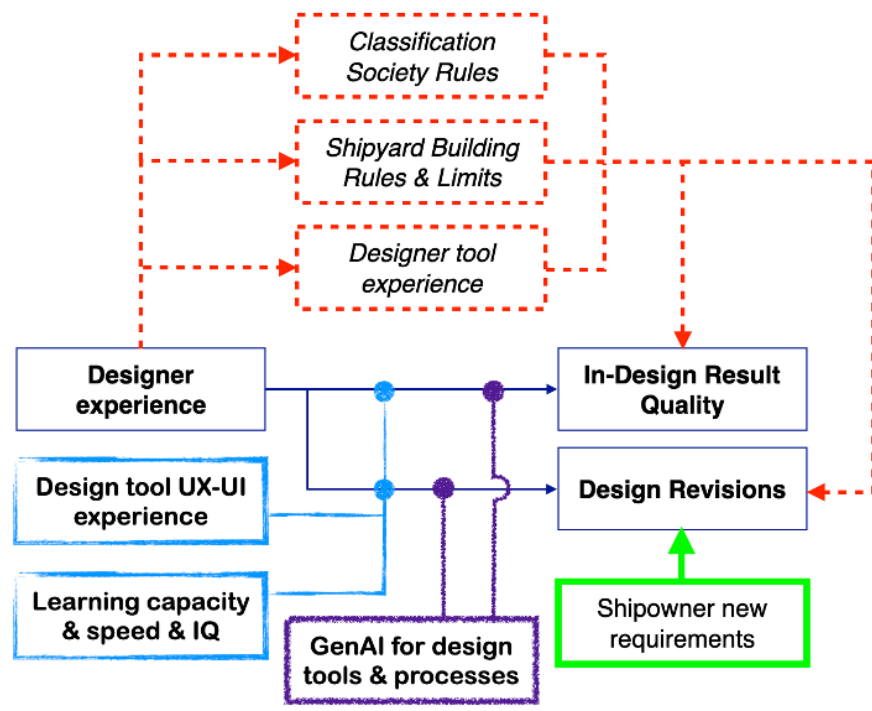


Figura 3.2: Flujo de la solución [Benayas-Ayuso y col., 2024]

### 3.3.1 Marco conceptual

El marco conceptual en el que se basa el desarrollo identifica la experiencia en el campo de trabajo, en este caso el diseño de buques, como la variable clave para lograr el resultado deseado (véase la figura 3.3). [Benayas-Ayuso y col., 2024]



**Figura 3.3:** Marco conceptual [Benayas-Ayuso y col., 2024]

Las variables que afectan al resultado son la calidad del producto diseñado y la cantidad o el número de revisiones necesarias para lograr un resultado óptimo. [Benayas-Ayuso y col., 2024]

La relación causal básica que hay que explorar es que la experiencia del diseñador permite reducir el número de revisiones y mejorar la calidad del diseño, garantizando así una solución más adecuada y eficaz en un plazo más breve. Además, la posibilidad de que el mismo equipo trabaje en diseños más complejos también es un factor para tener en cuenta. Sin embargo, esto siempre requiere la participación de equipos muy experimentados o con una gran capacidad de aprendizaje. Además, las normas aplicables de la sociedad de clasificación o del astillero, así como las limitaciones de diseño de las instalaciones, también afectan a la calidad del diseño y al número de cambios que hay que realizarle. [Benayas-Ayuso y col., 2024]

En tercer lugar, está la experiencia con las herramientas utilizadas en el proceso de diseño. Aunque el diseñador carezca de experiencia en un área específica, un conocimiento exhaustivo de las herramientas disponibles puede facilitar un trabajo de diseño más eficiente y centrado. Por el contrario, un diseñador muy experimentado puede experimentar una disminución de su rendimiento al cambiar a una nueva herramienta. Esto puede suponer una pérdida de control sobre el resultado esperado o un aumento del tiempo necesario para conseguirlo. Otro factor que influye, pero que no se trata en detalle aquí, son los cambios derivados de los requisitos del propietario. Estas suelen determinarse al inicio del proceso de diseño, pero los cambios en

el uso previsto del buque o los requisitos reglamentarios de los puertos o estados en los que atracará también pueden hacer necesarios ajustes en el diseño. [Benayas-Ayuso y col., 2024]

Si nos centramos ahora en las variables que moderan el resultado, uno de los factores es la experiencia del usuario (UX) y la interfaz de usuario (UI) de las herramientas de diseño. La facilidad y comodidad de uso, así como la inductividad de la interfaz, permiten que los usuarios adquieran destreza en una fase más temprana, lo que reduce el impacto de la experiencia de usuario en la calidad del diseño. [Benayas-Ayuso y col., 2024]

La siguiente variable de esta categoría es la capacidad y velocidad de aprendizaje, además de la inteligencia de los diseñadores. Estas variables tienen un impacto significativo en el resultado de los diseños, tanto en términos de su calidad como del tiempo necesario para completarlos. [Benayas-Ayuso y col., 2024]

El objetivo en este punto es mejorar las variables moderadoras —experiencia UX/UI de la herramienta de diseño y capacidad y velocidad de aprendizaje e inteligencia— y reducir los efectos de las variables mediadoras —normas de la sociedad de clasificación, normas y límites de construcción de los astilleros y experiencia de la herramienta de diseño—, reduciendo así su impacto en los resultados. Para ello, se está desarrollando un sistema de inteligencia artificial generativa que permite al usuario priorizar las tareas de diseño y libera recursos cognitivos que, de otro modo, se utilizarían para hacer frente a las numerosas restricciones que impiden una solución óptima. [Benayas-Ayuso y col., 2024]

Este elemento, «GenAI for design tools & processes», se convierte en una nueva variable moderadora que debería cambiar las reglas del juego para mejorar los resultados del diseño. [Benayas-Ayuso y col., 2024]

### 3.3.2 Definición de la metodología: herramientas de diseño de buques, estudio en profundidad

#### ¿En qué etapas pueden ayudar las herramientas CAD en IoS?

En el contexto del diseño clásico, el enfoque en espiral es una metodología habitual. Sin embargo, se ha demostrado que la incorporación del CAD desde el principio reduce la duración total del proceso de diseño. Esto se debe a que el CAD permite una verificación visual más exhaustiva de los diseños, que se ajusta más a la perspectiva del usuario. Así lo corroboran las conclusiones de los estudios citados en [Perez-Martinez y Perez Fernandez, 2023, Pérez-Martinez y Pérez Fernández, 2021].

El primer reto de la Internet de las Cosas (IoS) son los sensores que ayudan al funcionamiento del buque. Se trata de sensores que requieren al menos dos cables para su alimentación y otros dos para la lectura de la señal asociada. Además, son sensores que tienen una mezcla de componentes mecánicos y electrónicos, colocados en un lugar determinado, independientemente de si son fácilmente accesibles o no. Estos sensores, basados en el enfoque de la Internet de las Cosas, deben tener un identificador único dentro del buque, así como en su representación en el modelo digital, germen del gemelo digital que utilizará dicha información [Liu y col., 2016].

El segundo reto del IoS se refiere a la fase de producción, concretamente a la identificación unívoca de las piezas. Esto se puede lograr mediante el uso de códigos de barras, códigos de respuesta rápida (QR Code), etiquetas de identificación por radiofrecuencia (RFID) [Benayas-Ayuso y col., 2018; Sokolov, Sergey y col., 2022] o una combinación de estos. Este tipo de identificador se utiliza para facilitar la agregación de piezas para la lista de materiales de fabricación (MBOM), para determinar el estado de cada elemento MBOM durante el proceso de producción y también puede incluir un indicador de los requisitos de preprocesamiento u otros pasos en la cadena de producción.

Estas etiquetas se generan, se utilizan y, en la mayoría de los casos, se desechan o se destruyen en el proceso de producción, lo que implica costes adicionales en el proceso de MBOM que no están directamente relacionados con ellas. Este coste adicional está plenamente justificado por el ahorro que se genera a lo largo de todo el proceso, al reducirse las horas de trabajo dedicadas a la preparación de cada MBOM, el control, el traslado al taller, el procesamiento y la entrega al siguiente paso de la cadena de producción [Benayas-Ayuso y col., 2018].

Basándose en esta identificación única, parte del proceso, si no todo, puede realizarse de forma autónoma, es decir, el procesamiento de las bobinas de tubos [Fraga-Lamas y col., 2016]. Esto permite realizar determinados trabajos en cualquier momento de la jornada laboral, haciendo posible que los palés de montaje de cada MBOM estén preparados fuera del horario laboral y listos para que los trabajadores de la construcción naval continúen el siguiente turno de trabajo.

Estos retos tienen un nexo común: la identificación. El CAD moderno tiene una forma única de identificar cada elemento o aparición en el almacén de datos (base de datos propia, base de datos basada en archivos individuales o delegada en PLM) y el diseño de trabajo actual del usuario, independientemente de si se realiza en una escena 3D, un diseño 2D/1D o un dibujo, o cada elemento en la simulación de un sistema. La identificación interna no solo puede

ser única, sino también una combinación de otros atributos que pueden ser útiles para la secuencia de elementos de marcado seleccionada, lo que convierte al CAD en una de las partes más importantes de la cadena para generar este código único, la semilla para la identificación única [Liu y col., 2016].

La generación del código de identificación único puede hacerse sobre la marcha en herramientas CAD, basándose en patrones, o, en caso de creación de artículos, guardarse como un atributo trazable especial para cada artículo o como un nuevo elemento relacionado con la capacidad y la evolución del ciclo de vida completo (en PLM). En este punto, cuando se genera una nueva tubería o se divide en carretes de trabajo, CAD puede rellenar un atributo con este código o crear y vincular un nuevo elemento que represente la etiqueta vinculada con el trozo de tubería [Pérez-Martínez y Pérez Fernández, 2021].

Este segundo enfoque es mucho mejor, ya que nos ayuda durante el ciclo de vida de esta nueva entidad, pues nos indica cuándo se genera el elemento y si está lo suficientemente maduro para ser procesado. Además, cuando se imprime y se une al elemento, este tiene asignado un componente de catálogo coleccionable en el almacén, o después del procesamiento del taller para elementos como las bobinas, que tienen dos fases de producción, la creación del elemento y la instalación del elemento. Tras este proceso, los dos elementos, el artículo a identificar y la etiqueta, se convierten en un nuevo artículo de fabricación que se utilizará en la producción. Además, se pueden obtener fechas de control del proceso de fabricación sincronizando el sistema de control de almacén basado en un ERP [Benayas-Ayuso y col., 2018] con el sistema CAD o, mejor aún, con su herramienta de control del ciclo de vida, el PLM.

Una ventaja de generar estas etiquetas en el CAD y almacenarlas en el PLM es que se pueden establecer relaciones y controles de no repetición, así como ver la evolución de las etiquetas y su uso, lo que permite al astillero estudiar el proceso desde el punto de vista de los artículos. Estos nuevos datos configuran un nuevo conjunto de información que procesará el sistema de IA conectado. [Benayas-Ayuso y col., 2024]

En el proceso de fabricación, en el taller o a bordo del buque, cuando los artículos se convierten en piezas procesadas, como las bobinas de tuberías, la identificación y la colocación del sensor pueden colisionar o, más bien, pueden utilizarse como el mismo artículo, como una etiqueta de identificación-sensor (etiqueta de sensor RFID) [Benayas-Ayuso y Pérez Fernández, 2018a]. En este caso, el coste de la identificación del proceso MBOM se reduce en gran medida al utilizar este sensor de identificación en la futura fase de explotación del buque, ya que permite obtener una medición del parámetro y obtener una identificación que puede utilizarse en el sistema de a bordo para ayudar en el trabajo del ingeniero del buque [Benayas-Ayuso y col., 2018].

La última idea se refiere a las etiquetas sensores RFID, que son únicas y pueden devolver una medición de cualquier parámetro del elemento etiquetado. El coste se reduce gracias a la ausencia de cables —RFID pasiva o RFID pasiva asistida por batería (BAP RFID)— con una medición siempre lista para usar, que solo se lee cuando el proceso lo estima oportuno, realizándose tantas veces como sea necesario para garantizar el pleno funcionamiento. El coste del sensor utilizado se reduce y su sustitución es relativamente sencilla. Además, puede

colocarse en partes del recipiente que no sean fácilmente accesibles, con la posibilidad de obtener el valor requerido. Esta última idea solo se refiere a los sensores RFID pasivos que no requieren mantenimiento para su funcionamiento [Pérez Fernández y Regueira, 2022].

Un ejemplo de esta idea son las etiquetas de tensión de tipo RFID en la estructura externa o interna del buque. Estas pueden aplicarse en la cuaderna u otros elementos principales sometidos a grandes tensiones durante la navegación. De este modo, se puede realizar un estudio, ya sea en la fase de construcción o durante el traslado de los bloques del taller a la grada, o bien durante la navegación del buque [Benayas-Ayuso y col., 2018].

A partir de estas ideas, el software CAD debe ayudar en todo el proceso de diseño con soluciones finales para el proyecto del buque y herramientas o ayudas en la fase de producción que no se destruyan durante la misma y que puedan ser útiles después. La forma de conseguirlo es el núcleo de los nuevos desarrollos basados en las nuevas tecnologías que se pueden utilizar hoy en día. [Benayas-Ayuso y col., 2024]

### **Cómo puede ayudar CAD en la distribución de etiquetas y sensores**

En base al punto anterior, el proceso de etiquetado ayuda en las etapas de producción, preservando la trazabilidad de los materiales del MBOM, así como del producto final obtenido a partir de este MBOM procesado, que es un nuevo material que se debe añadir en la siguiente etapa de producción controlada en el ERP a partir de los elementos de diseño PLM aprobados. Este nuevo producto representa un nuevo material que se incluirá en otro MBOM. [Benayas-Ayuso y col., 2024]

La capacidad de identificar fácilmente los elementos permite a los usuarios cotejar estas etiquetas con el sistema de diseño del astillero, lo que devuelve información sobre el elemento del catálogo (componente), la posición relativa y la ubicación final en el buque, los elementos relacionados, etc., lo que facilita la integración de esta información con una herramienta de comprobación del sistema CAD-PLM [Liu y col., 2016, Pérez-Martinez y Pérez Fernández, 2021].

Además, si esta información se carga en el software de a bordo, se puede acceder a ella durante el funcionamiento, lo que permite verificar fácilmente el estado del elemento comparando los parámetros de rendimiento reales con los valores de referencia en el gemelo digital cargado en el sistema del buque [Pérez Fernández y Regueira, 2022].

Los datos del gemelo digital comparados con los obtenidos de una etiqueta de identificación también permiten conocer las acciones de mantenimiento recomendadas, predecir posibles fallos imprevistos y realizar trabajos de sustitución antes de que se produzca la rotura del elemento [Pérez Fernández y Regueira, 2022].

En el caso de los sensores, su distribución por el buque se ve influida por la información procedente de las siguientes fuentes [Benayas-Ayuso y col., 2024]:

1. Las sociedades de clasificación
2. La experiencia de construcción del astillero
3. Requisitos de los fabricantes de equipos originales (OEM) y capacidad de detección en

los equipos

4. Los requisitos especiales de información del armador.

A partir de estas normas, el diseñador debe ubicar los sensores en todos los sistemas del buque, que pueden ser cableados o inalámbricos, de modo que sean accesibles con los cables o mediante un lector de radiofrecuencia. Además, hay que añadir etiquetas de identificación de las piezas para automatizar el proceso de producción. Estas etiquetas pueden incluir un código legible acompañado de un código de barras y/o QR, o incluso utilizar una etiqueta mixta que admita el sistema de código visual (legible + código de barras y/o QR) con un identificador RFID, que es más fácil de leer cuando la etiqueta se mantiene en un lugar oculto del sistema del buque. [Benayas-Ayuso y col., 2024]

Estas dos ideas, el etiquetado y la combinación de etiqueta y sensor, pueden abrumar a los usuarios con información, lo que convierte las fases de diseño y verificación del diseño en una pesadilla. Estos son ejemplos típicos en los que las herramientas de los sistemas CAD pueden validar, mejorar e incluso corregir algunos de los errores más comunes basándose en las lecciones aprendidas de diseños anteriores o, tras aplicar las normas de la sociedad de clasificación, corregir el diseño para cumplir ambas. [Benayas-Ayuso y col., 2024]

El desarrollador de software debe ayudar al diseñador con potentes herramientas CAD que puedan manejar un conjunto de normas (reglas de diseño) que se apliquen al modelo, permitiendo a los usuarios verificar, comprender y corregir el diseño fácilmente. Según nuestra propuesta de etiquetado, establecer etiquetas de identificación y, cuando sea posible, sustituir una etiqueta de identificación por un sensor RFID combinado ayudará a reducir el coste global del ciclo de vida [Liu y col., 2016].

Según nuestra propuesta de etiquetado, establecer etiquetas de identificación y, cuando sea posible, sustituir una etiqueta de identificación por un sensor RFID combinado ayudará a reducir el coste global del ciclo de vida. [Benayas-Ayuso y col., 2024]

Sobre la base de los requisitos anteriores, un conjunto de estas normas es el siguiente [Benayas-Ayuso y col., 2018]:

1. Etiqueta visible desde pasillos o corredores comunes para código de barras o código QR.
2. Para RFID, las etiquetas BAP deben ser accesibles para el mantenimiento de la batería.
3. Las antenas lectoras deben poder leer todos los elementos asignados, es decir, la distancia no debe superar los 30 m sin obstáculos y los 15 m con obstáculos. Esto establece el radio de control de los lectores automáticos [Benayas-Ayuso y Perez Fernandez, 2018a].
4. Evite las zonas de sombra alrededor de las etiquetas RFID.

La ubicación de las etiquetas y los sensores es uno de los problemas que pueden resolverse mediante reglas de diseño en el sistema CAD. Sin embargo, si las reglas, controles y otras ayudas no están bien diseñadas, pueden abrumar al diseñador en el proceso. [Benayas-Ayuso y col., 2024]

## Reglas de diseño propias

Los astilleros y las oficinas de ingeniería se enfrentan a un gran problema a la hora de desarrollar nuevos diseños, que se ve magnificado por la pérdida de experiencia y los importantes requisitos de formación que deben cumplir los ingenieros menos experimentados para producir diseños de alta calidad. Para resolver estas dificultades, las empresas han desarrollado reglas de diseño que los usuarios deben aprender y aplicar a su trabajo actual. Esta idea no es nueva, ya que siempre se ha incluido un conjunto de normas de diseño en el libro de procedimientos de los astilleros. [Benayas-Ayuso y col., 2024]

Los problemas surgen cuando las autoridades de diseño de los astilleros deben comprobar que el diseño se ajusta a este libro de procedimientos en un entorno en evolución, lo que les desborda y genera muchos retrasos en el proceso de diseño, muchas revisiones del diseño y, a veces, errores humanos basados en la incomprensión del proceso. [Benayas-Ayuso y col., 2024]

Una solución natural sería incorporar el CAD, que ayudaría al usuario a seguirlos y comprobarlos, y permitiría a los responsables de ingeniería (una de estas autoridades de diseño de los astilleros) verificar e informar de las no conformidades. [Benayas-Ayuso y col., 2024]

La forma de afrontar este cambio afecta al resultado, incluso desde el punto de vista de la escalabilidad. [Benayas-Ayuso y col., 2024]

Hay demasiadas opciones para resolver este problema, pero desde la experiencia y el punto de vista de los autores, las tres formas más comunes en que el desarrollador de CAD puede afrontarlo son la máquina de estado finito, el software CAD configurable/evolutivo y una herramienta de motor de inteligencia artificial generativa (GenAI). [Benayas-Ayuso y col., 2024]

En el enfoque de la máquina de estado finito, el desarrollador de software estudia el problema, ofrece una solución al cliente como mejora del sistema y la incluye en la siguiente versión. Este era el antiguo enfoque tradicional. Los principales problemas de este método son [Benayas-Ayuso y col., 2024]:

1. Cada regla programada en el núcleo principal de la aplicación debe estar predefinida, funcional y técnicamente, e incluida.
2. Ofrece una forma rápida de comprobar, pero establece un escenario rígido para el cambio de reglas.
3. Los desarrolladores de CAD deben contactar continuamente con los clientes (de forma eficiente y ágil) o contar con un equipo de soporte altamente capacitado que pueda traducir de forma eficiente a los desarrolladores los cambios necesarios en las reglas.
4. Las nuevas reglas no pueden aplicarse al modelo hasta que se lanza la siguiente versión o actualización del software, lo que a veces también requiere reconstruir la base de datos o los archivos CAD utilizados en el diseño.

Si se quiere mejorar la solución anterior con un enfoque evolucionado, el desarrollador CAD debe generar una capacidad de configuración en la solución, manual o basada en una herramienta, que ayude al cliente a crear sus propias reglas. Este es el enfoque actual de la

mayoría de los desarrolladores de software, no solo en CAD, sino también en otras soluciones de software. Sin embargo, este enfoque suele desbordar al departamento informático del cliente. Además, este conjunto de reglas puede ser difícil de aplicar al diseño final porque requiere tiempo de interpretación, tiempo de aplicación y tiempo de informe. Los principales problemas de este método son [Benayas-Ayuso y col., 2024]:

1. Consumo de tiempo de comprobación si se hace en la fase de diseño: retraso.
2. Programación de las reglas. Pueden colisionar en los procesos de diseño.
3. Aplicación de informes y acciones automáticas. No se conocen las posibles soluciones.

La tercera vía, que se basa en el marco conceptual expuesto, intenta minimizar todos los efectos de los elementos e incluso reducir la variable principal, la experiencia del diseñador en el campo de trabajo, creando el efecto de un equipo unipersonal en el grupo de diseñadores. [Benayas-Ayuso y col., 2024]

Al igual que los enfoques discutidos anteriormente, es necesario definir algunas reglas, pero la forma en que las definimos es en lenguaje natural, estableciendo un cambio de estado en el motor subyacente para las reglas. El CAD debería integrarse con una herramienta GenAI, lo que permitiría al astillero autoconfigurar un conjunto de reglas de diseño mediante la «lectura» del libro de reglas de diseño normativo asignado, aprendido a medida que trabajan los usuarios, etc. [Benayas-Ayuso y col., 2024]

Las reglas se crean como resultado de los requisitos leídos de la normativa aplicable, y crean un conjunto de características que se aplicarán al diseño final. La aplicación de la regla puede interpretarla fácilmente el usuario final, estableciendo esta característica como booleana (coincide/no coincide), una lista de estados (que permite un resultado tipo máquina de estados finitos), un número resultado de una simulación auto aplicada, o incluso un informe descriptivo de los problemas mostrados. El peso de cada característica puede normalizarse para reducir el impacto de cada una en el escenario de comprobación. Esto se puede hacer añadiendo un libro de reglas de rendimiento para los resultados del informe. [Benayas-Ayuso y col., 2024]

Todos estos conjuntos de reglas de diseño autoconfiguradas se aplican como ejemplos de entrenamiento de los resultados del sistema GenAI, comprobándolos con proyectos anteriores finalizados y generando informes para ser validados por el usuario (validando la solución GenAI). Una vez que la integración CAD de GenAI está entrenada y validada para realizar tareas basadas en estas reglas, podemos utilizarla en un diseño real [Benayas-Ayuso y col., 2024]:

1. Aprendizaje de la evolución de la fase de diseño.
2. Aprendizaje sobre las soluciones aplicadas a los problemas descubiertos.
3. Aplicar algunas soluciones automáticas a partir de las lecciones aprendidas.
4. Crear sus propias reglas de diseño para mejorar el diseño final.

La capacidad de mejora autónoma de la solución permite reentrenar y volver a aplicar cualquier alteración de las reglas de diseño, garantizando que todos los casos del diseño del buque se actualizan de forma coherente. Para reducir ineficiencias, este proceso de validación puede

completarse durante la noche y revisarse por la mañana por el validador del sistema de diseño correspondiente a la zona afectada. El proceso es tan sencillo como cargar en el sistema una versión actualizada de las reglas. [Benayas-Ayuso y col., 2024]

Gracias a la incorporación de la capacidad GenAI de un motor de cálculo proposicional, cada regla nueva o modificada de la Sociedad de Clasificación puede generar nuevas reglas de diseño o modificar las existentes, que se vuelven a aplicar automáticamente al diseño. Este proceso implica la verificación, la generación de informes, la aplicación de nuevas soluciones a los casos existentes y, en algunos casos, la emisión de una orden de retención MBOM para evitar la repetición de trabajos en el proceso de construcción naval. Además, este enfoque facilita la evaluación de las implicaciones financieras asociadas a la aplicación de una nueva norma. [Benayas-Ayuso y col., 2024]

Este enfoque no es evidente y requiere un esfuerzo adicional por parte del desarrollo CAD, ya que incluye algunas de las ventajas de la segunda solución, aplicándola sin esfuerzo y disminuyendo los problemas abrumadores asociados a ella. Por parte del cliente, no existe una solución Customer Off the Shelf (COTS). El cliente debe definir las reglas, entrenar la solución GenAI CAD solo con los requisitos del astillero, las capacidades y las reglas basadas en proyectos anteriores y en los límites físicos del astillero y, a continuación, empezar a utilizarla. El último paso establece el tiempo de retraso desde la implementación de la solución y sus posibles ventajas; sin embargo, una vez que todo está en marcha, queda demostrado que reduce el tiempo de comercialización, el número de incumplimientos y no conformidades. [Benayas-Ayuso y col., 2024]

### **Elementos CAD/PLM que deben controlarse mediante IA y tablas base**

GenAI se basa en la comprensión del lenguaje natural y en la interacción con las personas en este sentido, pero las herramientas de diseño y simulación, o PLM/ERP, tienen un lenguaje diferente que la GenAI debe aprender y procesar. Esto implica que hay que entender el CAD como una herramienta para crear, modificar, atribuir y simular los diferentes elementos que intervienen en el proceso de modelado, así como las aprobaciones, validaciones, gestión de históricos y efectividad aplicada en la herramienta PLM, o el procesamiento de BOM en la herramienta ERP, registro de asignación de recursos a los diferentes procesos, ofertas de materiales, recogida de materiales, etc. atribuir y simular los diferentes elementos que intervienen en el proceso de modelado, así como las aprobaciones, las validaciones, la gestión de históricos y la efectividad aplicada en la herramienta PLM o el procesamiento de BOM en la herramienta ERP, el registro de asignación de recursos a los diferentes procesos, las ofertas de materiales, la recogida de materiales, etc. Esto nos enfoca en una única dirección: podemos establecer un conjunto de elementos que estudiar mediante diferentes metodologías de IA basadas en un nuevo «lenguaje» hablado por diseñadores, fabricantes y todas las personas y herramientas involucradas en el proceso. [Benayas-Ayuso y col., 2024]

El usuario interactúa con la herramienta de diseño, con los comandos y los parámetros necesarios para completar todas las operaciones de diseño. Esto se hace en una sesión, siguiendo una secuencia y generando un conjunto de objetos en la memoria del ordenador, que pueden guardarse en una base de datos, un archivo o un elemento PLM como solución final. Esto establece el primer elemento de conflicto: no todos los elementos creados por el

usuario en una sesión se guardan; algunos se descartan y la lección está en el proceso, no en el resultado aplicado. [Benayas-Ayuso y col., 2024]

Para recoger todos estos datos, es necesario considerar el CAD como un sensor, obteniendo datos de todas las operaciones realizadas por el usuario. La forma de llevarlo a cabo consiste en establecer un nuevo conjunto de colectores de acciones para adquirir toda esta información y guardarla (de la misma forma que se define para los elementos en CAD, un elemento PLM o un conjunto de tablas en una base de datos) [Benayas-Ayuso y col., 2024].

Para este trabajo, hemos seleccionado el enfoque de solución de base de datos utilizado en lenguaje Python con bibliotecas de IA como PyTorch y NumPy. El esquema de tablas propuesto requiere tres tablas para guardar los datos generados durante la sesión de usuario [Benayas-Ayuso y col., 2024]:

1. Acciones del usuario: cada comando o acción que el usuario ha realizado en CAD debe guardarse en la tabla. En esta tabla se guardarán todos los comandos o acciones que el usuario haya realizado en CAD.
2. Pasos de la acción. Algunas acciones tienen un paso sencillo, pero otras requieren rellenar un formulario con mucha información.
3. Atributos/parámetros rellenados en el paso. Al igual que los pasos de acción, cada paso puede requerir un valor simple o un conjunto de ellos.

Después de recopilar todos los datos de varias sesiones de diseño de usuario, podemos empezar a aplicar deep learning, clasificación de datos y otras metodologías para extraer nuevas acciones para futuras interacciones con los usuarios. [Benayas-Ayuso y col., 2024]

Esta tabla ayuda a la capa CAD de GenAI a aprender a diseñar con CAD o a interactuar con herramientas de simulación, pero hay un enlace que debe ser rellenado por el usuario. Se necesita indicar los requisitos que realizan las acciones realizadas si estos elementos se encuentran en el libro de reglas de diseño del astillero, de la sociedad de clasificación o de la lista de requisitos del cliente. Todos estos documentos deben estar en el PLM, separados en párrafos y requisitos, y vinculados a los objetos de solución generados por las herramientas de diseño CAD/Simulación. [Benayas-Ayuso y col., 2024]

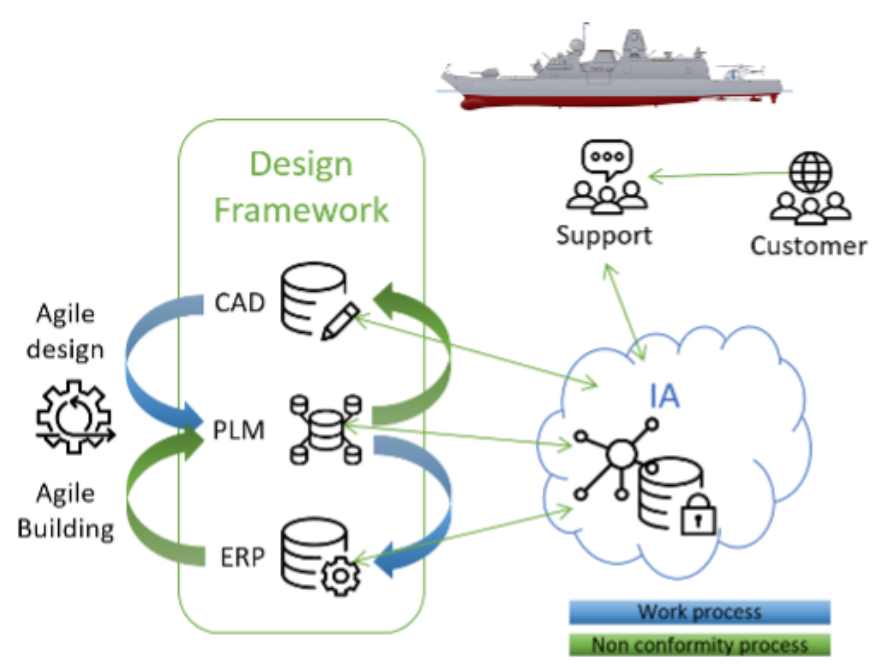
Este documento se basa en los datos recopilados en el diseño del sistema de refrigeración del motor principal, desde los requisitos de potencia hasta los límites del sistema de la sociedad de clasificación, las normas de diseño del astillero y otros documentos obligatorios que se deben tener en cuenta en el diseño actual. [Benayas-Ayuso y col., 2024]

### 3.3.3 Modelo

#### Arquitectura de la solución GenAI para CAD

La solución GenAI, basada en CAD, ha requerido varias fases de aplicación en la parte de Desarrollo de Software: analizar su sistema CAD desde el punto de vista de los requisitos del cliente en materia de automatización de procesos, de los requisitos de información del equipo de soporte, de las necesidades del equipo de desarrollo para nuevos desarrollos, de la investigación de incidencias, de la recodificación de la solución y de su despliegue ágil, así como incluir alguna prueba de verificación [Harjamäki y col., 2024; Taiwo y col., 2024].

Tras el análisis, la selección del motor GenAI más adecuado obligó a formar parte de la arquitectura mostrada en la figura 3.4, que se basa en la integración en el producto de un conjunto de métodos de intercambio de información que permiten generar algoritmos de aprendizaje autónomo para producir conocimiento de base, así como generar herramientas autónomas de comprobación del diseño para aplicarlas durante el turno de noche, o incluso, con estaciones de trabajo potentes, durante las horas de trabajo, y finalmente, generar herramientas para una aplicación autónoma de la solución [Daase. y col., 2024].



**Figura 3.4:** Esquema de la solución propuesta [Benayas-Ayuso y col., 2024]

Para ponerlo en práctica, será necesario programar el sistema CAD y el motor GenAI, creando dos herramientas separadas. La primera es el CAD estándar con capacidades modificadas para informar a la capa GenAI del nuevo lenguaje de intercambio que debe comprender; la segunda, en cambio, puede ser una solución COTS o un nuevo sistema creado por el proveedor de software, en función de las capacidades de este. Lo más importante para la solución del sistema GenAI es que se base en un motor GenAI de código abierto o en un conjunto de ellos que satisfaga nuestras necesidades y nos permita una integración bastante sencilla [Daase. y col., 2024; dos Santos e Santos y col., 2024].

## Conversión de un sistema CAD/PLM en un conjunto de sensores IoT

La integración de un sistema de diseño asistido por ordenador (CAD) y de gestión del ciclo de vida del producto (PLM) con una solución de diseño generativo (GenAI) requiere el establecimiento de una serie de puntos de control. La incorporación de acciones, pasos y parámetros CAD en procesos de diseño integrales permite a los usuarios llegar a soluciones para conjuntos determinados de requisitos de diseño. La metodología utilizada para investigar esta cuestión nos permite alcanzar nuestro objetivo, que es transformar nuestro CAD en un sensor IoT capaz de recoger datos de uso para su posterior procesamiento en nuestro sistema de IA [Daase. y col., 2024].

Además, existen herramientas adicionales dentro del proceso que proporcionan información que es necesario tener en cuenta. Esta información se refiere a las relaciones entre elementos. Las relaciones entre los elementos de diseño constituyen la base de la gestión del ciclo de vida del producto (PLM). La PLM permite identificar las relaciones directas y jerárquicas, que pueden estudiarse como un segundo punto sensor para recopilar datos en el sistema de diseño. [Benayas-Ayuso y col., 2024]

Además, la simulación es una herramienta CAD con valores de salida e informes. En este caso, GenAI es capaz de leer y comprender los datos relevantes y traducirlos a los procesos CAD de diseño, lo que permite aplicar la corrección de simulación necesaria. En conjunto, estas dos capacidades abarcan la mayor parte de la información que puede extraerse de un sistema CAD/PLM. [Benayas-Ayuso y col., 2024]

Sin embargo, una vez que se han obtenido y procesado los datos, es esencial difundir los hallazgos al usuario de una manera que muestre la mejora del proceso de diseño. Para lograr esto, el sistema GenAI también debe configurarse para ofrecer las siguientes posibilidades [Benayas-Ayuso y col., 2024]:

- Un sistema de información (es decir, un informe).
- Un sistema de guía o ayuda interactiva.
- Un actuador autónomo que pueda realizar los pasos de manera supervisada pero no intervenida.

El componente informativo del sistema debe ser sencillo e interactivo con la interfaz de usuario durante la sesión de trabajo. Esto permitirá al usuario interactuar de forma guiada, lanzando los elementos en los que necesite intervenir, utilizando para ello un informe documental paso a paso. De este modo, se establece un sistema de retroalimentación de las acciones propuestas mediante la validación paso a paso por parte del usuario, que también se almacena en el sistema GenAI. [Benayas-Ayuso y col., 2024]

El sistema CAD, actuando como actuador, representa una etapa crucial en el proceso. Debe interpretar un conjunto de instrucciones generadas por el sistema GenAI y modificar de forma autónoma el diseño basándose en la validación y verificación de los pasos realizados en la fase de información del sistema. [Benayas-Ayuso y col., 2024]

Esta sección se centra en los requisitos para transformar un sistema CAD en un sensor/actuador IoT eficaz, garantizando la generación de una cantidad de datos suficiente para construir

un conjunto válido. Para ello, es necesario establecer ciertas especificaciones funcionales [Benayas-Ayuso y col., 2024].

1. El primer paso es crear una herramienta de sensores CAD. Es esencial que cada comando o diálogo dentro del sistema genere una entrada que será recogida por el sistema de IA. La señal contiene la siguiente información para su procesamiento: un número de referencia de identificación único, un identificador único universal (UUID) o un identificador de objeto (OID), el usuario que realizó la acción, el modo/módulo de trabajo en el que se realizó la acción, la fecha/hora del inicio de la acción, los datos del comando/diálogo (por ejemplo, nombre e información solicitada), los datos almacenados que apuntan a la segunda información del sensor (punto 2), la fecha/hora del final de la acción, el comando/diálogo padre y el posible tipo de error.
2. En segundo lugar, la herramienta de sensores PLM: cada elemento del diseño de trabajo debe generar una entrada que contenga un número de referencia de identificación único, un UUID u OID, la identificación única del elemento en el sistema PLM, la fecha y hora de creación o de última modificación, los atributos (la creación requiere todos, pero la modificación gestiona solo el delta, solo los modificados) y la geometría 3D en un formato neutro, intercambiable e interpretable.

La combinación de estos dos sensores activos permite al sistema de IA obtener información suficiente durante una sesión de trabajo del usuario para crear varios ejemplos. En función de las capacidades de la oficina de ingeniería, la solución puede entrenarse y probarse en un tiempo relativamente corto. [Benayas-Ayuso y col., 2024]

Los sensores facilitan la creación de una relación entre objetos, así como una base de datos histórica de modificaciones. El motor de IA se entrena analizando estos datos históricos, lo que permite crear un modelo de aprendizaje. [Benayas-Ayuso y col., 2024]

## Modelos GenAI utilizados en el caso a estudio

Dado que el diseño de un buque es un proceso largo, el estudio se ha aplicado al sistema de refrigeración del motor principal de un buque no comercial. Se han seguido los requisitos de la sociedad de clasificación, el astillero y el armador mediante modelos y datos de diseño [Benayas-Ayuso y col., 2024].

Una vez establecida la estructura de adquisición de datos y las herramientas implementadas en CAD y PLM, el siguiente paso consiste en alimentar el sistema de modelos de formación. Los datos se introducen en una base de datos, que posteriormente se procesa utilizando PYTORCH como lenguaje de procesamiento de IA. El modelo GenAI seleccionado es una mezcla que se nutre de múltiples metodologías, siguiendo el sistema VAE de Exemplar [Norouzi y col., 2020].

Los datos de entrenamiento proceden de dos fuentes distintas y se han procesado como una variedad de datos de entrenamiento [Benayas-Ayuso y col., 2024]:

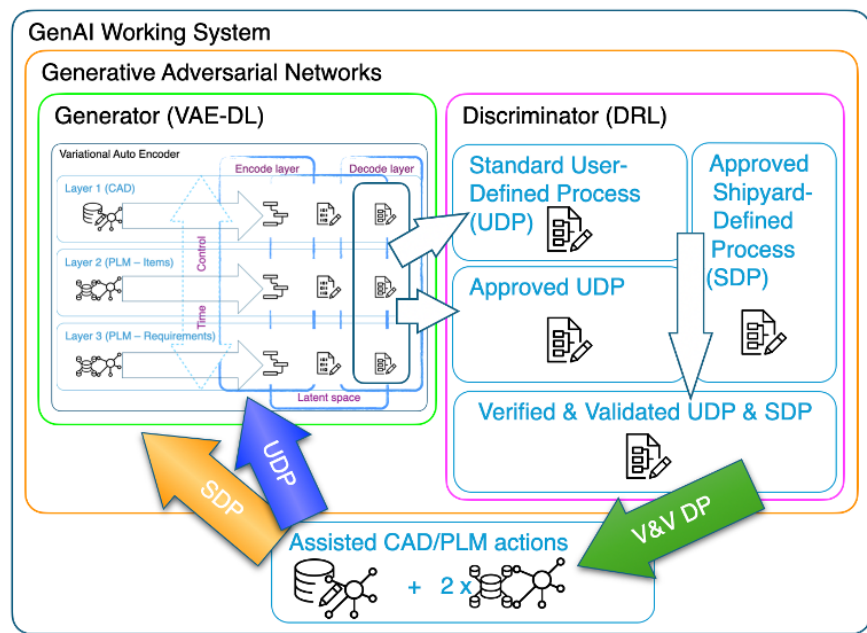
1. Los requisitos para la gestión del ciclo de vida del producto (PLM) se basan en una serie de factores, como las normas empresariales y los límites de producción establecidos por el propio astillero, las normativas establecidas por las sociedades de clasificación y los términos específicos recogidos en los acuerdos contractuales. Los datos se presentan en formato textual y pueden clasificarse en dos categorías principales: párrafos que comprenden información contextual y requisitos, que son cadenas de texto que deben cumplirse. Estos se basan en el lenguaje natural y, por tanto, requieren traducción al lenguaje de acciones PLM/CAD del modelo GenAI.
2. Las acciones, relaciones y elementos PLM/CAD incluyen pre-acciones, acciones y resultados de simulación. Este es el nuevo lenguaje en el que se entrena nuestro modelo GenAI.
3. Los tiempos de las acciones PLM/CAD representan la organización temporal de los procesos de trabajo. Este es el resultado real de nuestro sistema, que puede ayudar al usuario durante la secuencia de diseño, reduciendo así el tiempo necesario para el desarrollo y obteniendo una solución final verificada. La terminología y las estructuras gramaticales empleadas en esta propuesta de sistema GenAI se derivan del lenguaje desarrollado recientemente.

Las capacidades del modelo GenAI VAE permiten la implementación de un codificador que produce el mismo resultado que el obtenido con datos de entrenamiento curados a partir de procedimientos de usuario. Para validar los resultados del modelo VAE, este se emplea como generador de un modelo GAN, en el que el discriminador se entrena utilizando las decisiones del usuario relativas a los pasos propuestos para los procesos. [Benayas-Ayuso y col., 2024]

El sistema GenAI, tal y como se ilustra en la Figura 3.5, puede describirse de la siguiente manera [Benayas-Ayuso y col., 2024]:

1. El generador se encarga de generar la salida a partir de la entrada. Se emplea un modelo VAE con una ruta de aprendizaje profundo para entrenar las capas de codificación y decodificación. Este modelo maneja toda la información conocida sobre los procesos de

diseño y los requisitos y la gestiona a través de las tres capas definidas en la sección anterior. La función principal de este componente es generar un nuevo conjunto de procesos derivados de los requisitos seleccionados para su posterior validación. Inicialmente, esto lo lleva a cabo el componente discriminador y, posteriormente, el Comité de Verificación y Validación (V& VC). El V& VC está constituido por procesos previamente sugeridos y aplicados por el usuario, ya sea parcialmente o en su totalidad, o rechazados como solución no válida para el usuario. Si se rechaza un proceso, también es necesario que el V& VC lleve a cabo una revisión.



**Figura 3.5:** Modelo de formación continua a partir del diseño y los requisitos [Benayas-Ayuso y col., 2024]

2. El discriminador es el sistema que dispone de un conjunto de rutinas pre entrenadas que deben actualizarse para incluir los principales procesos del astillero, el usuario clave y el propietario del producto que han sido aprobados y rechazados por el V& VC. Una vez aprobado un proceso propuesto, se proporciona al usuario una guía paso a paso que incluye la sugerencia de parámetros e instrucciones sobre las acciones posteriores a la validación. Las acciones sustituidas se almacenan en el sistema como alternativas potenciales al proceso de diseño propuesto (ilustrado por la flecha morada que apunta al generador), que luego alimenta el modelo VAE del generador como nuevas rutinas de entrenamiento. Las acciones rechazadas se identifican en el sistema como alternativas no válidas dentro del proceso de diseño propuesto tras la revisión V& VC. Esto facilita el proceso de aprendizaje profundo por refuerzo del discriminador, permitiéndole aprender la metodología V& VC a través de la experiencia.
3. Los elementos del discriminador son los siguientes. Como se ilustra en la figura, el Proceso Definido por el Usuario (UDP) representa un proceso aplicado por el usuario a una tarea específica para abordar un requisito concreto. Por su parte, el Proceso Definido por el Astillero (SDP) es un componente del libro de normas de diseño destinado a

satisfacer una norma de construcción concreta. Los procesos mencionados deben ser aprobados por los propietarios del producto y los usuarios clave de cada disciplina (refuerzo). Sin embargo, en el caso de procesos relativamente sencillos, la aprobación de un usuario clave es suficiente para su aplicación. Por consiguiente, la figura muestra tanto los procesos aprobados por el usuario como los procesos estándar, que requieren un nivel de aprobación inferior. El proceso estándar debe ser sencillo y servir de base para las tareas de diseño y simulación. Una vez aprobados, los procesos deben someterse a una comprobación de valor y viabilidad (V& VC), durante la cual los usuarios clave y los propietarios del producto determinan si aprueban o rechazan el valor del proceso en el discriminador. Esta decisión determina si el proceso se certifica o no. Solo los procesos certificados pueden recomendarse a los usuarios finales.

Estos procesos se generan normalmente a partir de la experiencia de los usuarios en todas las fases de la construcción naval, pero también se nutren de la actividad diaria. Esta última será la base de nuestro proceso Variational Auto Encoder (VAE), que permitirá a la parte generadora “imaginar” nuevos procesos para resolver el mismo requisito de diseño del astillero o del armador. [Benayas-Ayuso y col., 2024]

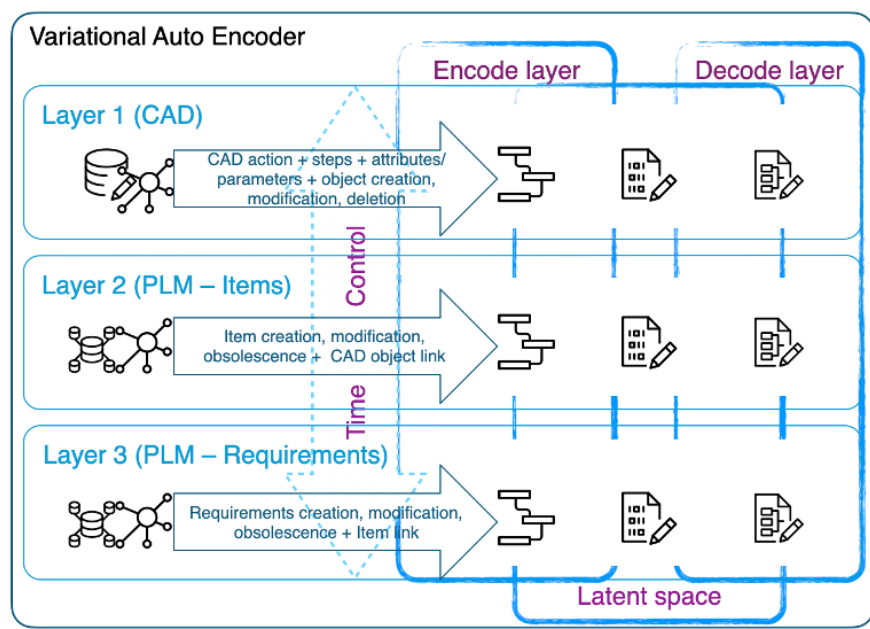
Cuando el sistema detecta una rutina de diseño, comprueba si existe alguna similar en el sistema y, basándose en ella, sugiere la misma, si es adaptable, o una nueva bastante similar y con valores adaptados. Esto es verificado por la capa discriminadora antes de ser sugerido al usuario, comprobando no solo el proceso, sino también los valores sugeridos. [Benayas-Ayuso y col., 2024]

Este tipo de proceso debe ser muy rápido para ayudar al diseñador en el momento oportuno. Esto ha supuesto un gran desafío para el diseño de la solución. [Benayas-Ayuso y col., 2024]

Los datos generados, que aparentemente no se incluyen en ninguna rutina durante la sesión de diseño del usuario, alimentan el modelo de entrenamiento de la capa VAE. La formación se ha realizado en todas las fases del diseño: conceptual, funcional y de detalle. Estas se complementan en el proceso de fabricación, las no conformidades en el diseño, los problemas del proceso de fabricación y los detalles. [Benayas-Ayuso y col., 2024]

Cada capa del modelo VAE para el generador tiene su propia información, que se ha poblado en el sistema GenAI mediante las herramientas específicas desarrolladas para ello. Para más detalles, véase la figura 3.6. [Benayas-Ayuso y col., 2024]

El autocodificador variacional procesa todas las capas de información (figura 3.6). La capa de codificación utiliza una mezcla gaussiana no paramétrica, similar al VAE ejemplar [Norouzi y col., 2020], junto con una Aproximación Estocástica de Perturbación Simultánea Compleja (CSPSA) [Gidi y col., 2023], dado que algunas de las acciones admiten un gran número de valores de atributos y parámetros, y deben considerarse desconocidos en el proceso de entrenamiento.



**Figura 3.6:** Capas necesarias para el entrenar el modelo VAE [Benayas-Ayuso y col., 2024]

Todos los modelos se han desarrollado para ayudar a los usuarios, no para sustituirlos. Como resultado, el usuario siempre tiene el control sobre el sistema GenAI y ningún dato se autogenera en el diseño final, excepto los procedimientos totalmente verificados, validados y curados. [Benayas-Ayuso y col., 2024]

Para poner en marcha el sistema, se deben desactivar las sugerencias durante los primeros pasos. Una vez que los datos del diseño están lo suficientemente maduros, las salidas de la VAE comienzan a interactuar con el discriminador GAN. El discriminador aprende de la decisión de la VAE, y también se ve afectado por los problemas y no conformidades planteadas por los revisores del diseño. Las acciones emprendidas se han incluido en el sistema como elementos de tipo cambio de ingeniería y se han vinculado con los elementos, obteniendo los tres tipos de elementos: problema, afectado y solución. Esta información se procesa en la segunda capa de VAE para generar acciones específicas basadas en las correcciones realizadas (figura 3.6). [Benayas-Ayuso y col., 2024]

Las reglas y los límites de diseño de los astilleros se incorporan al sistema mediante un objeto de modelo de datos PLM de requisitos especiales, que permite alimentar el sistema de una forma diferente. Se trata de un procesamiento del lenguaje natural (PLN) que transforma los requisitos en rutinas de diseño que se ejecutarán y comprobarán en el modelo. Una vez realizada la traducción de NLP a rutinas de diseño, la capa VAE de requisitos puede llenarse

con toda esta información y cualquier cambio en estas reglas puede informar de su impacto en el diseño en curso. [Benayas-Ayuso y col., 2024]

### 3.3.4 Ajuste de hiperparámetros de cada red neuronal con Optimización Bayesiana

#### Optimización de parámetros - Métodos estudiados

Algunas de las metodologías que se pueden emplear para ajustar los hiperparámetros de una red neuronal son:

- *Búsqueda en Cuadrícula (Grid Search)*: La búsqueda en cuadrícula puede considerarse un enfoque de “fuerza bruta” para la optimización de hiperparámetros. Ajustamos el modelo utilizando todas las combinaciones posibles tras crear una cuadrícula de posibles valores discretos de hiperparámetros. Registramos el rendimiento del modelo de cada conjunto y, a continuación, elegimos la combinación que produce los mejores resultados.

El inconveniente que tiene es que pasará por todas las combinaciones intermedias de hiperparámetros, lo que hace que la búsqueda en la malla sea computacionalmente muy costosa.

- *Búsqueda aleatoria (Randomized Search)*: Como su nombre indica, el método de búsqueda aleatoria selecciona valores al azar, a diferencia del método de búsqueda en cuadrícula, que utiliza un conjunto predeterminado de números. En cada iteración, la búsqueda aleatoria prueba un conjunto diferente de hiperparámetros y registra el rendimiento del modelo. Devuelve la combinación que proporcionó el mejor resultado después de varias iteraciones. Este método reduce los cálculos innecesarios.

El inconveniente que se plantea es la posibilidad de que el resultado no sea la combinación ideal de hiperparámetros es una desventaja.

- *Optimización Bayesiana (Bayesian Optimization)*: La optimización bayesiana, trata la búsqueda de hiperparámetros óptimos como un problema de optimización. Tiene en cuenta los resultados de la evaluación anterior a la hora de seleccionar la siguiente combinación de hiperparámetros y aplica una función probabilística para elegir la combinación que probablemente produzca los mejores resultados. Este método descubre una buena combinación de hiperparámetros en relativamente pocas iteraciones.

El inconveniente radica en que requiere una comprensión del modelo probabilístico subyacente. Lo que hace que personas no versadas en la estadística Bayesiana no sean capaces de entender y evolucionarlo.

Como conclusión se saca que como la búsqueda en cuadrícula y la búsqueda aleatoria suelen ser ineficaces porque evalúan muchas combinaciones de hiperparámetros inadecuadas sin tener en cuenta los resultados de las iteraciones anteriores, sin embargo, en el caso de la optimización Bayesiana, el método de resolución converge de una manera más eficaz a unos parámetros adecuados del problema.

Los científicos de datos utilizan un modelo probabilístico cuando la función objetivo es

desconocida. El modelo probabilístico estima la probabilidad del resultado de la función objetivo de una combinación de hiperparámetros basándose en los resultados de evaluaciones anteriores.

$$P(\text{puntuación}(y)|\text{hiperparámetros}(x))$$

Es un “sustituto” de la función objetivo, que puede ser el error cuadrático medio (RMSE), por ejemplo. La función objetivo se calcula utilizando los datos de entrenamiento con la combinación de hiperparámetros, e intentamos optimizarla (maximizar o minimizar, dependiendo de la función objetivo seleccionada).

La aplicación del modelo probabilístico a los hiperparámetros es computacionalmente barata en comparación con la función objetivo. Por lo tanto, este método suele actualizar y mejorar el modelo probabilístico sustituto cada vez que se ejecuta la función objetivo. Una mejor predicción de los hiperparámetros reduce el número de evaluaciones de la función objetivo necesarias para obtener un buen resultado. Los procesos gaussianos, la regresión de bosque aleatorio y los estimadores de Parzen estructurados en árbol (TPE) son ejemplos de modelos sustitutos.

El modelo de optimización bayesiana es complejo de aplicar, pero las bibliotecas comerciales como Ray Tune pueden simplificar el proceso. Merece la pena utilizar este tipo de modelo porque encuentra una combinación adecuada de hiperparámetros en relativamente pocas iteraciones. Sin embargo, en comparación con la búsqueda en cuadrícula o la búsqueda aleatoria, debemos calcular la optimización bayesiana de forma secuencial, por lo que no permite el procesamiento distribuido. Por lo tanto, la optimización bayesiana lleva más tiempo pero utiliza menos recursos informáticos.

## Optimización Bayesiana para VAE

Lo primero que debemos estudiar es los parámetros a optimizar, para ello, nos hemos centrado en los más importantes para nuestro estudio:

- **Dimensión Latente (Latent Dimension):** La dimensión latente es el tamaño del vector que representa la versión comprimida de los datos de entrada en la VAE. La dimensión latente afecta a la cantidad de información que la VAE puede codificar y decodificar, y a la diversidad de los resultados generados. Una dimensión latente mayor puede captar más detalles y variaciones, pero también puede provocar un exceso de ajuste e inestabilidad. Una dimensión latente menor puede obligar a la VAE a aprender representaciones más eficientes, pero también puede limitar la expresividad y la calidad de los resultados. Para elegir la dimensión latente óptima, puede experimentar con distintos valores y comparar el rendimiento de reconstrucción y generación de la VAE.
- **Tasa de Aprendizaje (Learning Rate):** La tasa de aprendizaje es la cantidad en que la VAE actualiza sus ponderaciones durante cada iteración del proceso de entrenamiento. La tasa de aprendizaje influye en la rapidez y la eficacia con que la VAE converge a una buena solución. Una tasa de aprendizaje más alta puede acelerar el entrenamiento, pero también puede hacer que la VAE sobrepase el punto óptimo y diverja. Una tasa de aprendizaje más baja puede garantizar una mayor estabilidad y precisión, pero también

puede ralentizar el entrenamiento y atascarse en un mínimo local. Para elegir la mejor tasa de aprendizaje, puede utilizar un programador de tasa de aprendizaje que adapte la tasa de aprendizaje según el progreso del entrenamiento, o puede utilizar un método de prueba y error, y controlar la función de pérdida y las métricas de validación.

- **Coefficiente Beta (Beta Coefficient):** El coeficiente beta es un hiperparámetro que equilibra la compensación entre la pérdida de reconstrucción y la pérdida de divergencia KL en el VAE. La pérdida por reconstrucción mide lo bien que la VAE puede reconstruir los datos de entrada a partir del vector latente, mientras que la pérdida por divergencia KL mide lo cerca que está la distribución latente de una distribución normal estándar. El coeficiente beta determina el peso que se da a cada componente de la pérdida. Un coeficiente beta más alto puede animar a la VAE a aprender un espacio latente más regularizado y desenmarañado, pero también puede degradar la calidad de la reconstrucción y la diversidad. Un coeficiente beta más bajo puede mejorar la fidelidad y riqueza de la reconstrucción, pero también puede hacer que el espacio latente se colapse e ignore la distribución a priori. Para elegir el coeficiente beta adecuado, puede probar diferentes valores y evaluar el compromiso entre reconstrucción y regularización.
- **Arquitectura de la red (Network Architecture):** La arquitectura de red es la estructura y configuración de las redes neuronales que forman el codificador y el decodificador de la VAE. La arquitectura de red influye en la complejidad y flexibilidad de la VAE y en su capacidad para tratar distintos tipos de datos. Por ejemplo, para datos de imagen, se pueden utilizar redes neuronales convolucionales (CNN) como codificador y decodificador, ya que pueden capturar características y patrones espaciales. Para los datos de texto, puede utilizar redes neuronales recurrentes (RNN) o transformadores como codificador y decodificador, ya que pueden manejar información secuencial y contextual. Para elegir la arquitectura de red óptima, puedes tener en cuenta las características y dimensiones de tus datos, y comparar distintos tipos y capas de red.

Una vez que hemos definido los hiperparámetros más importantes para la capa VAE de nuestro modelo podemos ver cuales son “atacables” mediante optimización bayesiana y cuales son de definición.

Empezaremos por el último, la arquitectura decidida como base para nuestra capa de VAE es variada, ya que tenemos varios elementos a interpretar (ver figura 3.6):

- **Capa 0:** es la capa subyacente a todas. Esta capa es la que se utiliza para el entrenamiento de interpretación del lenguaje natural. Para esta capa se han manejado varias alternativas:
  - **RNN:** Ya que permite modelos de lenguaje natural nuevo, basados en otros paradigmas distintos de los básicos. El conjunto de datos de entrenamiento puede ser variado y permite la interpretación completa de los datos. Este nos permite añadir con facilidad otros lenguajes no procesados.
  - **Transformadores:** Es el modelo base de Google, y permite jugar con diccionarios en diversos idiomas de lenguaje natural, por lo que es más fácil para trabajar en un entorno con multiplicidad de vocabularios habituales y técnicos. Debido a los

“diccionarios” requeridos, se ha tenido que descartar al tener que hacer uno nuevo que entendiera secuencias CAD, secuencias PLM y fuera capaz de interpretar cada requisito como una secuencia o conjunto de las dos anteriores.

- **Modelo Secuencia-a-Secuencia (S2SM)**: Este modelo permite, como los transformadores, realizar distintas traducciones entre distintas secuencias de elementos (lenguajes técnicos) y el lenguaje natural con el que estemos trabajando.
- **Capa 1**: Debido a las capacidades a adquirir se ha entrenado una RNN para el lenguaje “técnico” y se ha aplicado un S2SM para la parte de la interpretación en lenguaje natural de las acciones CAD.
- **Capa 2**: Al igual que el anterior, debido a las capacidades a adquirir ha sido necesarios usar una RNN para el lenguaje “técnico” de uso de la plataforma y se ha aplicado un S2SM para la parte de la interpretación en lenguaje natural de las acciones PLM.
- **Capa 3**: En este caso, se ha usado un modelo ya entrenado de lenguaje natural, de la librería SPACY, para tener una gran profundidad, se ha descargado el modelo más grande. En el entrenamiento, como los requisitos de buque son algunos de los elementos más importantes para la construcción, cada vez que se ha validado uno y se ha relacionado con los elementos que lo resuelven, las secuencias que han servido para generar ese elemento han sido la base del “traductor” a las otras dos capas, entrenando el modelo S2SM que permite la traducción inversa de lenguaje natural a lenguaje que entienden las capas de trabajo digital.

En resumen, se han creado dos diccionarios nuevos para cada una de las acciones que se realizan en el CAD y en el PLM, se ha entrenado cada una de las RNN y luego se ha empezado a trabajar en secuencias.

Como ya se ha definido el primer parámetro de cada VAE, ahora tenemos que optimizar el resto, para que el entrenamiento sea efectivo y se pueda usar en futuros desarrollos. La optimización bayesiana, también conocida como modelado sustituto, es una técnica particularmente interesante para optimizar funciones de caja negra [Shahriari y col., 2016].

## Optimización Bayesiana para GAN

Lo primero que debemos estudiar es los parámetros a optimizar, para ello, nos hemos centrado en los más importantes para nuestro estudio:

- **Tasa de Aprendizaje (Learning Rate):** La tasa de aprendizaje es la cantidad en que la GAN actualiza sus ponderaciones durante cada iteración del proceso de entrenamiento. La tasa de aprendizaje influye en la rapidez y la eficacia con que la GAN converge a una buena solución. Una tasa de aprendizaje más alta puede acelerar el entrenamiento, pero también puede hacer que la GAN sobrepase el punto óptimo y diverja. Una tasa de aprendizaje más baja puede garantizar una mayor estabilidad y precisión, pero también puede ralentizar el entrenamiento y atascarse en un mínimo local. Para elegir la mejor tasa de aprendizaje, puede utilizar un programador de tasa de aprendizaje que adapte la tasa de aprendizaje según el progreso del entrenamiento, o puede utilizar un método de prueba y error, y controlar la función de pérdida y las métricas de validación.
- **Número de períodos (Number of Epochs):** Es el número de iteraciones completas del conjunto de datos de entrenamiento que debe realizarse. Un lote debe tener un tamaño mínimo de uno y un tamaño máximo menor o igual que el número de muestras del conjunto de datos de entrenamiento. Para el número de períodos de tiempo, es posible elegir un valor entero entre uno e infinito.
- **Tamaño del Lote (Batch Size):** Es el número de ejemplos de entrenamiento utilizados en una iteración del proceso de entrenamiento. Determina cuántas muestras procesa el modelo antes de actualizar sus pesos y desviaciones. La elección del tamaño del lote puede tener un profundo efecto en la dinámica de aprendizaje del modelo y en la forma de las curvas de aprendizaje.
- **Arquitectura de la red (Network Architecture):** La arquitectura de red es la estructura y configuración de las redes neuronales que forman el generador y el discriminador de la GAN. La arquitectura de red influye en la complejidad y flexibilidad de la GAN y en su capacidad para tratar distintos tipos de datos.
  - **GAN Vanilla:** Este es el tipo más simple de GAN. Aquí, el generador y el discriminador son simples perceptrones multicapa básicos (MLPB). En Vanilla GAN, el algoritmo es realmente simple, intenta optimizar la ecuación matemática utilizando el descenso de gradiente estocástico.
  - **GAN condicional (CGAN):** CGAN puede describirse como un método de aprendizaje profundo en el que se establecen algunos parámetros condicionales. En CGAN, se agrega un parámetro adicional 'y' al generador para generar los datos correspondientes.

También se colocan etiquetas en la entrada del Discriminador para que este ayude a distinguir los datos reales de los datos falsos generados.
  - **GAN convolucional profunda (DCGAN):** DCGAN es una de las implementaciones de GAN más populares y también la más exitosa. Está compuesta por redes convolucionales (CNN) en lugar de perceptrones multicapa (MLP).

Las CNN se implementan sin agrupamiento máximo, que de hecho se reemplaza por un paso convolucional. Además, las capas no están completamente conectadas.

- **Pirámide Laplaciana GAN (LAPGAN)**: La pirámide Laplaciana es una representación de imagen lineal invertible que consta de un conjunto de imágenes de paso de banda, espaciadas una octava entre sí, más un residuo de baja frecuencia. Este enfoque utiliza múltiples redes generadoras y discriminadoras y diferentes niveles de la pirámide laplaciana.

Este enfoque se utiliza principalmente porque produce imágenes de muy alta calidad. La imagen se reduce primero en cada capa de la pirámide y luego se aumenta nuevamente en cada capa en un paso hacia atrás donde la imagen adquiere algo de ruido de la GAN condicional en estas capas hasta que alcanza su tamaño original.

- **GAN de superresolución (SRGAN)**: SRGAN, como sugiere su nombre, es una forma de diseñar una GAN en la que se utiliza una red neuronal profunda junto con una red adversaria para producir imágenes de mayor resolución. Este tipo de GAN es particularmente útil para escalar de manera óptima imágenes nativas de baja resolución para mejorar sus detalles y minimizar los errores al hacerlo.

Una vez que hemos definido los hiperparámetros más importantes para la capa GAN de nuestro modelo podemos ver cuales son “atacables” mediante optimización bayesiana y cuales son de definición.

Empezaremos por el último, la arquitectura decidida como base para nuestra capa de GAN. Se va a implementar un DCGAN, ya que permite múltiples entradas de distinta índole (lenguaje) y ser validadas todas por igual.

En el caso de la capa de generación, no tenemos que tomar ninguna decisión, ya que ha sido sustituida por el VAE y sus redes y capas.

En el caso de la capa de discriminación, el entrenamiento se va a hacer con los diccionarios que hemos definido en la capa VAE, pero sin usar ninguno de los datos generados de momento, hasta que sean verificados por el usuario.

Los parámetros a estudiar son:

- Tasa de aprendizaje, es la primera y es la única que admite optimización bayesiana en el modelo que hemos establecido. Esto es debido a que es la única que puede variar, sin que varíe los datos de entrada de esta capa que son los de entrenamiento de la capa VAE.
- Número de períodos, representa el número de interacciones que deben pasarse por el proceso de datos. Se ha establecido que sea el primer múltiplo de 4 que incluya los ejemplos de los diccionarios de CAD + PLM. Por lo que no admite, en esta fase del estudio, optimización bayesiana. Esto se ha establecido de manera que siempre se pase un mínimo de 4 veces por el conjunto coordinado de datos CAD y PLM.

- *Tamaño* de lote, se ha establecido que sea el primer Primo cercano a la cuarta parte del tamaño del número de periodos. Ya que este número es un número múltiplo de cuatro siempre estará un número entero representando a el tamaño de lotes. El que sea un primo es porque de esa manera nunca será múltiplo de cuatro y obliga a que se pase varias veces por el conjunto de datos, de manera que se hace un entrenamiento completo. Al igual que el parámetro anterior, en esta fase del desarrollo no admite optimización bayesiana.

Aunque los números pueden parecer caprichosos, se basan en la experiencia del doctorando en la optimización de procesos, aunque estos no pertenezcan al campo de estudio de la inteligencia artificial.

Los números primos siempre van a requerir al menos de su producto como número de pasadas por el conjunto de datos, siendo el número mínimo de interacciones sobre el campo de datos estudio. De ahí el combinar un número primo con un múltiplo de cuatro, de manera que siempre haya al menos cuatro pasadas por todo el conjunto de datos.



# Capítulo 4

## Resultados

### 4.1 Estudio de ciberseguridad: Blockchain como primera capa

El estudio de ciberseguridad basado en el Blockchain como primera capa se ha realizado con el ejemplo de casa inteligente porque es el más cercano y fácil de trabajar para el doctorando.

Debido a que la complejidad que tiene una casa es similar en cuanto a interferencias a la que puede tener un conjunto de habitáculos de un buque, se ha considerado que es asimilable uno al otro.

Otro de los detalles a tener en cuenta es que dentro de una casa Existen jaulas de Faraday debido a las estructuras metálicas, las cuales generan una aplanamientos y ecos de la señal, en el caso de sensores IoT.

También se debe tener en cuenta que los sensores de domótica son de peor calidad que los industriales, por lo que los problemas que se puedan generar de interferencias, así como de difusión del dato, ayudan a generar un primer modelo que se puede considerar suficiente para esta capa de estudio.

Para completar este estudio se han tomado medidas dentro de una caseta metálica que se encuentra en el jardín y estas medidas eran transmitidas a un PLC que se encontraba dentro de la casa.

#### 4.1.1 Casa inteligente

Este estudio también puede aplicarse al caso de despacho u oficina pequeña inteligente, representando el primer nivel de abstracción.

La domótica crea un entorno de trabajo basado en sensores y actuadores que se conectan a la red interna de la casa mediante cable o vía WAN. El entorno generado a partir de objetos que obtienen o reciben datos está bajo el paraguas del IoT. Estas implementaciones tienen que ser de bajo coste, por lo que hay sensores inseguros y con altas prestaciones, que no permiten

entornos muy complejos. [Benayas-Ayuso y col., 2021]

Para llevar a cabo estas implementaciones, tal y como indican A. Dorri et al., debemos agrupar los sensores inseguros en clústeres que sirvan como nodos de trabajo, con una cabecera de clúster que se conecte con el controlador del clúster. El ecosistema IoT doméstico debe basarse en el paradigma de capa inmutable, en el que todos los dispositivos están identificados y registrados. Cualquier dispositivo nuevo debe ser añadido por el Smart Home Manager [Dorri, Kanhere, Jurdak y Gauravaram, 2017].

Los tres retos que hay que abordar con este caso de estudio son la optimización de recursos, la privacidad y la centralización [Dorri, Kanhere y Jurdak, 2017].

La aplicación interna requiere [Benayas-Ayuso y col., 2021]:

1. Dispositivos.
2. Cabecera de clúster que actúa como controlador de los dispositivos conectados.
3. Controlador del clúster/Smart Home Miner. Este es el único minero de todo el blockchain. El POW se sustituye por una cabecera de permisos para validar las transacciones del bloque, que permiten o deniegan que se añadan previamente a la cadena.
4. Sistema de almacenamiento local. Puede estar integrado con el minero o como un dispositivo independiente. El método de almacenamiento utilizado es First-In-First-Out (FIFO) para mantener enlazados todos los datos y operaciones de los dispositivos.

Con estos elementos, vamos a construir una blockchain local para controlar el ecosistema IoT. Las características de esta blockchain son [Benayas-Ayuso y col., 2021]:

1. Utilización de un método ligero de creación de hash, que reduce los tiempos de comprobación, como el propuesto por A. Bogdanov et al. [Bogdanov y col., 2011].
2. No se requiere POW.
3. La cabecera de cada bloque se divide en la cabecera de bloque propiamente dicha y la cabecera de permisos.
4. Cualquier operación se valida contra una cabecera de permiso, que es un pequeño conjunto de operaciones/transacciones válidas para ser realizadas por los diferentes agentes de la Blockchain, como dispositivos y usuarios.
5. Cualquier transacción se valida contra la cadena de bloques y se registra en un bloque. Si es válida, la blockchain establece una clave compartida con un intervalo de tiempo válido en ambas cabeceras de clúster para que los dispositivos puedan comunicarse directamente. De esta forma, se elimina el retraso en la comprobación continua con el minero.
6. Cuando termina la validez de la clave, se envía una operación de fin de transacción al minero.
7. Cualquier adición de un nuevo dispositivo requiere que el Smart Home Manager se añada a un nodo del clúster, lo que genera una transacción de génesis que se almacenará

- compartiendo una clave con el dispositivo mediante un Diffie-Hellman generalizado [Delfs y Knebl, 2002].
8. Los nodos del clúster pueden contener tantos dispositivos como sea necesario, de uno a muchos.
  9. Los smartphones, como dispositivos válidos, pueden conectarse a la blockchain como consumidores, generando operaciones de petición de datos.
  10. Los dispositivos inteligentes deben incluirse en la cabecera del permiso.
  11. Solo Smart Home Manager puede validar nuevos dispositivos y modificar esta cabecera.
  12. Modificar la cabecera de permisos cierra el bloque actual y abre uno nuevo en el minero.
  13. El minero local puede conectarse a otras casas inteligentes para crear una red externa que pueda actuar de forma coordinada.
  14. Además, el minero local puede conectarse a servicios en la nube para ofrecer la información de la casa inteligente a los dispositivos permitidos a través de dichos servicios.

Este es un ejemplo de implementación de la tecnología blockchain + IoT en un entorno ciberseguro que mantiene los tres pilares de los retos: optimización de recursos, privacidad y centralización [Dorri, Kanhere y Jurdak, 2017]. Además, cumple los requisitos de seguridad de la CIA, confidencialidad, integridad y disponibilidad, en inglés, Confidentiality, Integrity and Availability [Komminos y col., 2014].

#### 4.1.2 Smart Home Cluster para empresas de seguridad

Algunas empresas de seguridad ofrecen también servicios de domótica a sus clientes, que pueden integrarse con su propio sistema antirrobo. No obstante, en algunas casas también es necesario compartir datos para comprobar si alguien ha entrado en nuestra propiedad cuando no estamos. [Benayas-Ayuso y col., 2021]

Este caso de uso establece un paradigma especial, ya que algunos datos deben subirse a la red de la empresa de seguridad. [Benayas-Ayuso y col., 2021]

El caso de implementación anterior sentó las bases de una implementación de este tipo, creando un ecosistema válido, pero tenemos que cambiar tres de los requisitos: la cabecera de permisos, la gestión de clústeres de seguridad y la compartición de datos entre varias nubes. [Benayas-Ayuso y col., 2021]

La cabecera de permisos debe dividirse en tres segmentos: permisos de cabecera de la empresa de seguridad, permisos de acceso compartido de dispositivos domésticos y permisos de acceso de gestor doméstico inteligente. El primero solo puede ser modificado por el gestor de la empresa de seguridad a través de su nube empresarial, a la que el cliente debe tener un acceso seguro. El segundo requiere un acuerdo doble firmado digitalmente entre el gestor de la empresa de seguridad y el propietario de la vivienda inteligente, que debería ser el gestor de la vivienda inteligente. El tercero solo puede ser modificado por el propietario. Esto requiere implementar una capa de control especial en el minero de blockchain. [Benayas-Ayuso y col., 2021]

Los dispositivos de seguridad también deben estar conectados al hogar inteligente, pero su gestión en el hogar inteligente solo puede realizarla la empresa de seguridad. [Benayas-Ayuso y col., 2021]

Los dispositivos compartidos, como la información sobre puertas abiertas, persianas, consumo de agua y otros que indican movimiento en la casa, pueden parametrizarse para enviar datos a la empresa de seguridad si se detecta un funcionamiento anómalo. Este segundo grupo de dispositivos necesita cargar datos en ambos servicios en la nube, el del propietario inteligente y el de la empresa de seguridad. [Benayas-Ayuso y col., 2021]

Dado que el servicio en la nube de la empresa de seguridad debe ejecutar una cadena de bloques para controlar, clasificar y almacenar cifrados todos los datos del propietario, se puede activar un contrato inteligente para cada cliente con el fin de comprobar si los datos compartidos están fuera de los parámetros de uso común. Para la firma de este contrato, el propietario inteligente, a través del minero doméstico inteligente, debe validar cada vez que el contrato inteligente necesita ser actualizado, lo que permite que el minero doméstico inteligente sea un minero en la blockchain de la empresa de seguridad. [Benayas-Ayuso y col., 2021]

### 4.1.3 Actualización controlada para dispositivos IoT

Los dispositivos IoT requieren que el software del sistema operativo y las aplicaciones estén actualizados para evitar agujeros de seguridad. También debe actualizarse el firmware de los dispositivos, pero este paso es menos habitual y suele requerir una intervención presencial. [Benayas-Ayuso y col., 2021]

La actualización del software, al igual que la de las aplicaciones, en un sistema altamente distribuido es una pesadilla, pero en este proceso, también blockchain puede ayudar. [Benayas-Ayuso y col., 2021]

El primer paso consiste en crear una representación virtual del entorno IoT, para lo cual se crean dos capas de blockchain: una para alojar los dispositivos IoT reales y la otra para alojar la representación virtual. [Benayas-Ayuso y col., 2021]

Los recursos virtuales se centrarán en toda la gestión de mantenimiento de los dispositivos reales y, con esto, se programará el comando de actualización de software para que se realice fuera del horario comercial y se lanzará cuando se llegue a ese horario, siempre y cuando el dispositivo no tenga carga. Para ello es necesario seguir varios pasos [Benayas-Ayuso y col., 2021]:

1. Una copia incremental de la información actual del dispositivo IoT como copia de seguridad, que se almacenará hasta que se realicen dos copias más, descartándola cuando no sea necesaria.
2. A continuación, el proceso de actualización iniciará la descarga de la actualización en el dispositivo.
3. El siguiente paso es la instalación de la actualización.

4. El proceso de verificación aplicado al dispositivo debe incluir la verificación del software, la validación del procedimiento y la verificación del dispositivo mediante una prueba unitaria en cada una de ellas.
5. Cuando todas las verificaciones se marcan como correctas, se actualiza una marca para el software liberado en la capa blockchain de control de actualizaciones.
6. Si una de las verificaciones falla, se aplica la recuperación al sensor y se instala la imagen de copia de seguridad. En este caso, se marca como no liberado y el mensaje de error de verificación se almacena en la cadena de Blockchain.

#### 4.1.4 Resultados del caso de ciberseguridad

Con esto se obtienen las siguientes figuras tipo tabla de combinación de tecnologías [4.1][4.2]:

Blockchain type	Requires strong POW	Hash generation	Header content	Read Access to other Blockchain
Cluster Controller Blockchain	✓		Previous block hash BC Software Version Cluster hash Devices hash	
Virtualization Blockchain	✓	✓	Previous block hash BC Software Version Cluster Controller hash Cluster hash Devices hash	Cluster Controller Blockchain
Software Updating Blockchain	✓	✓	Previous block hash BC Software Version Software update hash Backup block hash Affected Clusters hash Affected Devices hash	Virtualization Blockchain + Devices Backup Blockchain
Devices Backup Blockchain	✓	✓	Previous block hash BC Software Version Cluster Controller hash Cluster hash Devices hash	Cluster Controller Blockchain + Virtualization Blockchain
Operation Blockchain		✓	Previous block hash BC Software Version Permission Policy hash Cluster data limits	Virtualization Blockchain + Permission Blockchain
Permission Blockchain	✓	✓	Previous block hash BC Software Version Cluster Controller hash	

**Figura 4.1:** Definición de blockchain para completar una red empresarial [Benayas-Ayuso y col., 2021]

Blockchain type	Header modification opens a new branch	Can modify?			Read Access to other Blockchain
		Agents	Permission Miners	Installation Miners	
Cluster Controller Blockchain				✓	
Virtualization Blockchain	✓		✓		Cluster Controller Blockchain
Software Updating Blockchain	✓		✓✓ Requires a double check confirmation, because could affect to IoT ecosystem.		Virtualization Blockchain + Devices Backup Blockchain
Devices Backup Blockchain				✓	Cluster Controller Blockchain + Virtualization Blockchain
Operation Blockchain	✓	✓	✓		Virtualization Blockchain + Permission Blockchain
Permission Blockchain	✓		✓		

**Figura 4.2:** Creación de bloques y relaciones entre cadenas de bloques [Benayas-Ayuso y col., 2021]

## 4.2 Estudio de Inteligencia Artificial Generativa

En el caso de la inteligencia artificial generativa, se ha visto que es un campo de amplio desarrollo, no solo se está aplicando a generaciones de vídeos automáticos y otros elementos, sino que estableciendo un sistema que permita al usuario en lenguaje natural, comunicarse con el CAD/PLM de manera sencilla para poder realizar sus tareas, permite mejorar mucha experiencia de usuario, haciendo que el trabajo se produzca de una manera mucho más natural y cercana.

El lenguaje que se ha establecido para poder comunicar las acciones CAD/PLM, basándose en el lenguaje natural del usuario y las capacidades que permiten la traducción de lenguaje natural a un lenguaje de operaciones que entiende el ordenador, ha mostrado que es el campo investigar de cara al futuro.

Para poder ajustar todos los datos necesarios para cada una de las redes neuronales que se han empleado en cada una de las capas del modelo VAE diseñado, se ha usado la optimización Bayesiana para cada uno de los parámetros. La ventaja que permite esta optimización es que se pueden ajustar más de un parámetro en cada iteración, por lo que se ha reducido con pocos ejemplos los tiempos de entrenamiento de cada una de las capas.

Debido a la complejidad de cada una de las capas de los múltiples modelos empleados, el entrenamiento de las mismas ha requerido mucho tiempo y esfuerzo, así como un alto grado de síntesis para poder acometer un ejemplo relativamente sencillo.

Los modelos de lenguaje natural que se han usado, permiten una conversación fluida con la máquina, pero, lo que no permiten, es la interpretación directa de los comandos que deben realizarse para cada uno de los casos. Este es el punto en el que se está portando una diferencia sustancial respecto a otros sistemas.

Los datos de sensórica se han utilizado para curar la parte del modelo que tiene que ver con el posicionado de sensores, aunque esta parte ha quedado relegada, está en los diccionarios de entrenamiento de la red neuronal aplicada a la parte CAD, como también en el diccionario de PLM para poder añadir toda la parte de ordenes de fabricación.

Esta parte del modelo no ha podido ser validada todavía, aunque está en la lista de comprobaciones futuras para continuar evolucionando este modelo.

### 4.2.1 Definición de diccionarios

En el caso de los diccionarios, debido a que el lenguaje de comunicación es diferente entre un ordenador y un programa de ordenador que el que existe entre dos personas, se han tenido que definir unos diccionarios especiales que permitan hacer que esos pasos que debe seguir alguien para trabajar con un ordenador Sean fácilmente traducibles a lenguaje natural.

Para ello se ha definido un metalenguaje que engloba los pasos que debe dar un usuario en un ordenador con una sola instrucción general, la cual requerirá de unos parámetros que se rellenarán en cada uno de los pasos.

Como ejemplo de este metalenguaje se ponen comandos para cada uno de los diccionarios, CAD y PLM (ver tablas 4.1 y 4.3):

**Tabla 4.1:** Ejemplo de diccionario implementado para CAD

Comando	Parámetros	Paso	Parámetro
Crear Equipo	Tipo de entidad Nombre del equipo	Menú: Editar >	
		>Nuevo ítem	
		Seleccionar tipo de ítem	Equipo
		Asignar identificación	Nombre equipo
		Crear entidad	Botón: Aceptar
Posicionar equipo	Nombre del equipo	Seleccionar equipo de la lista	Nombre de equipo
		Posicionar elemento	Botón derecho ratón Menú: Posicionar Item
	Punto de posición (X, Y, Z)	Seleccionar punto de inserción	Botón Cruz
		Vector de Rotación (X, Y, Z)	Corregir orientación
		Aceptar posición	Botón: Aceptar
	...		

Una vez definidos ambos diccionarios, se entrenará la red neuronal de tipo recurrente, con todos los comandos que se hayan usado.

En esta primera fase, solo se ha llegado al nivel de los comandos requeridos para el entrenamiento, en una segunda fase se va a intentar que estos comandos del diccionario se generen directamente desde la ayuda online del programa CAD o desde los manuales del PLM.

Para esta segunda parte, cuando se realice, se usarán los modelos de lenguaje (Large Language Model - libería SPACY), tanto en inglés como en español que se han descargado y están ya entrenados para la interpretación de lenguaje natural.

**Tabla 4.3:** Ejemplo de diccionario implementado para PLM

Comando	Parámetros	Paso	Parámetro
Aprobación equipo		Buscar elemento	Nombre del equipo
	Nombre equipo	Asignar	Botón derecho >
	Nombre del Workflow	Workflow	Workflow Manager >
			Aprobación de equipo
		Iniciar Workflow	Botón: Iniciar
	Nombre revisor	Asignar revisor	Desplegar lista >
		Nombre revisor	
	Nombre aprobador	Asignar aprobador	Desplegar lista >
			Nombre aprobador
		Enviar workflow	Botón: Aceptar
...			

### 4.2.2 Entrenamiento de las redes RNN

Se implementa una Red Neuronal Recurrente completa desde cero usando Python para el caso de los diccionarios de CAD y PLM. Para ello construimos un modelo de generación de texto utilizando una RNN. Entrenamos nuestro modelo para predecir la probabilidad de un carácter dados los caracteres precedentes. Es un modelo generativo. Dada una secuencia de comandos existente, muestreamos un comando siguiente a partir de las probabilidades predichas, y repetimos el proceso hasta que tengamos una acción completa.

Pasos generales a seguir:

- Inicializar las matrices de pesos  $U$ ,  $V$ ,  $W$  a partir de una distribución aleatoria y bias  $b$ ,  $c$  con ceros.
- Propagación hacia delante para calcular predicciones.
- Cálculo de las pérdidas.
- Propagación hacia atrás para calcular los gradientes.
- Actualizar los pesos en función de los gradientes.
- Repetir los pasos 2-5.

Para que nuestro modelo aprenda de los datos y genere secuencias de comandos, lo hemos tenido que entrenarlo durante algún tiempo y comprobar la pérdida después de cada iteración. Si la pérdida se reducía a lo largo de un periodo de tiempo, significa que nuestro modelo estaba aprendiendo lo que se espera de él.

Para el entrenamiento de cada uno de los diccionarios, se han definido unos parámetros de entrada, o hiperparámetros, que son los siguientes:

- El tamaño del vocabulario es igual al tamaño de cada uno de los diccionarios.
- Se ha establecido una capa oculta de 100 niveles.

Para conseguir un diccionario y una red recurrente de calidad suficiente, se han tenido que implementar secuencias de entre 3 a 10 comandos de manera que tuviéramos un conjunto de acciones suficientemente amplio.

Los comandos actúan como palabras, y la secuencias de acciones o conjunto de acciones actúan como frases, permitiendo de esta manera generar un lenguaje propio de trabajo de la máquina, con un nivel inteligible por las personas.

### 4.2.3 Entrenamiento de los modelos S2SM

En el caso de entrenamiento de los S2SM (Seq2Seq model), éste se comporta como una RNN pero con un parámetro más de entrada que es el vector de base de la traducción. Para ello hemos creado diccionarios de pares en los cuales se pone un requisito y todos los comandos que hacen falta para cumplirlo, de manera que la traducción se realiza desde el requisito hacia los comandos o viceversa. En este caso, hemos usado los diccionarios anteriores, así como una lista de requisitos base para su entrenamiento.

Los hiperparámetros usados, en este caso son:

- El tamaño del vocabulario es igual al tamaño de cada uno de los diccionarios.
- El modelo RNN para el lenguaje natural se usa directamente, no se entrena. Se ha implementado su uso en inglés y español.
- Se ha establecido una capa oculta de 150 niveles.

Este es el modelo más difícil de entrenar, ya que no es una traducción directa. Se han empleado secuencias de cada usuario durante los últimos años, de manera que se generase un diccionario (pares de requisitos vs acciones) de calidad suficiente como para su entrenamiento.

### 4.2.4 Entrenamiento del GAN

Para el entrenamiento de este modelo, se han usado los diccionarios de entrada Ya sea de la RNN como de la S2SM, usándose estos como los parámetros válidos. El generador ha sido sustituido por la VAE con todas sus capas, de manera que la entrada en lenguaje natural se convierte en la entrada por defecto para el usuario. Una entrada secundaria está basada en las secuencias de trabajo, que, cuando son validadas, se incorporan como datos base de el discriminador.

El generador ha sido sustituido por un modelo más complejo que el discriminador de manera que se intenta evitar el colapso de modo en el trabajo del mismo. Por eso, las secuencias de entreno han tenido que se curadas (revisadas) de manera exhaustiva para evitar que se produzca un sesgo en la red neuronal.

Los hiperparámetros usados, en este caso son:

- El tamaño del lote es igual al tamaño de cada uno de los diccionarios de secuencias dividido por el primer primo más cercano de la cuarta parte del tamaño de períodos. Esto se ha hecho para que en un número adecuado de ciclos, las secuencias se combinen de manera natural. En este caso, usar un primo, es el método que se debe hacer cada vez que queremos completar el trabajo sin posibilidad de que no haya colisiones en la forma de agrupar las secuencias y el barrido se produzca de manera efectiva.
- El tamaño de períodos se ha establecido en un múltiplo de 4 respecto al contenido de la suma de las secuencias combinadas CAD + PLM. Como estas secuencias son incrementales, se establece este control.
- Se ha establecido una capa oculta de 100 niveles.

#### 4.2.5 Aplicación al caso de ventilación y refrigeración de locales: Resultados

El caso de uso escogido ha sido el aire acondicionado de la sala de bombas de un buque, de manera que se han introducido todos los requisitos que fueran sociedad de clasificación y de diseño del propio astillero/armador, realizándose el diseño manual de dicha sala. Con esto se han generado todos los elementos de entrenamiento de las redes neuronales que trabajan en la capa del VAE.

En este diseño se han creado equipos, cables, tubos y todos los conductos de ventilación para el aire acondicionado, así como su soportado. Se han ido validando todos los requisitos, así como asignando tanto las acciones CAD como las acciones PLM a cada uno de los conjuntos de datos, se ha realizado su aprobación para el cierre de todas las acciones sobre el modelo y los datos.

Una vez que se ha terminado con el entrenamiento y se han ajustado todos los diccionarios, así como los y parámetros de cada una de las redes neuronales, si he realizado un test cambiando uno de los requisitos haciendo que la misma sala se tuviera que añadir otros consumidores que aumentaron el calor en la misma y así cambiar las necesidades de refrigeración. Esto se resume en dos requisitos nuevos:

- Creación de nuevos equipos para satisfacer las necesidades de refrigeración de otros elementos con agua salada.
- Estudio de la nueva calorimetría basada en las características de los componentes desde su catálogo, para evitar que el local suba de 45°.

Se le ha solicitado al sistema que identificara y listara los cambios necesarios a realizar, así como, usando la referencia de horas que tiene de cada acción, evaluará el coste de los cambios. La respuesta ha sido relativamente rápida, desde el punto de vista del usuario, no se ha tenido que esperar mucho. El sistema ha identificado con facilidad los cambios a realizar en los elementos de la sala, haciendo que se hayan podido evaluar los posibles cambios a dicha escena y el coste de los mismos.

Se le ha solicitado también al sistema que estudiara otras alternativas a la corrección propuesta, así como a toda la instalación. En este caso el sistema ha tardado más en reaccionar y de las opciones que ha ofrecido, había algunas que se descartaban directamente, pero alguna alternativa era interesante.

En una acción posterior, se ha requerido la realización del diseño de otro local del buque en cuanto a la parte de refrigeración con un resultado de un 70 % de acierto en la primera interacción, se le ha pedido que repasara los datos, teniendo que corregir manualmente un 10 % del diseño final de la parte de aire acondicionado.

El lenguaje usado ha sido siempre lenguaje natural, la respuestas cuando se han empleado preguntas si han emitido el lenguaje natural. En el caso del diseño, se ha podido interpretar el lenguaje natural a lenguaje CAD, permitiendo que con la mínima ayuda por parte del usuario, se haya podido realizar el diseño del aire acondicionado del nuevo local, cumpliendo todos los requisitos, incluido el nuevo para los casos de alto requerimiento de refrigeración.

# Capítulo 5

## Discusión

Este modelo ayuda al usuario en su trabajo diario ofreciéndole nuevas soluciones de diseño, comprobando que se cumplen los requisitos del armador y de la sociedad de clasificación, ayudándole a utilizar las normas del astillero y comprobando que el MBOM del diseño cumple los límites de construcción. También coordina la comprobación del diseño, la simulación y los requisitos en un método transparente para el usuario.

Cuando se produce un cambio en la normativa o en los requisitos del armador, el astillero o la empresa de ingeniería pueden cargarlo en el sistema para evaluar de antemano los cambios que es necesario realizar al crear, modificar o poner como obsoletos elementos, y en algunos casos, eliminar elementos erróneos. El sistema también comprobación el impacto de estos cambios en los elementos existentes y, en función de su madurez, ayuda a tomar decisiones sobre la implementación o no del cambio, o la realización de un cambio de configuración, que también afecta a la línea de producción.

De este modo, los procesos se implantan fácilmente en el astillero y en la oficina de ingeniería, ya que el sistema ayuda a seguirlos durante el proceso de cambio. El sistema actúa como un usuario más dentro del astillero, creando las no conformidades y siguiendo el flujo de revisión de problemas desde la Solicitud de Problema (PR) hasta el Aviso de Cambio de Ingeniería (ECN) en la capa PLM.

Además, esta solución integrada ofrece claras ventajas tanto a los clientes de CAD/PLM como al proveedor de software. Desde el punto de vista del cliente de CAD, ayuda a crear una base de conocimientos para futuros desarrollos de ingeniería y asiste en tareas repetitivas mediante la creación autónoma de macros para aplicar al diseño. Detecta automáticamente las secuencias de diseño y las ofrece al usuario como una solución de macros y acciones pregrabadas con sus atributos y parámetros cumplimentados, de forma que solo hay que confirmar la validez de cada paso de la solución y comparar y ofrecer secuencias alternativas para obtener el mismo diseño, reduciendo así el tiempo del proceso. En este paso, compara el enfoque de los usuarios para obtener un resultado y ofrece al usuario el conjunto de comandos más eficiente en tiempo, sin mostrar qué usuario ha desarrollado el proceso de diseño más eficiente.

Otras ventajas que obtiene el usuario CAD son que el sistema puede auto detectar anomalías en el diseño basándose en elementos con condiciones aplicadas equivalentes que obtienen información diferente; las reglas de diseño pueden comprobarse y aplicarse automáticamente al diseño actual sin ningún esfuerzo adicional en un sistema totalmente curado. Proporciona una métrica para clasificar a los usuarios según su competencia en el uso de CAD/PLM y los resultados obtenidos, lo que permite al astillero o a la oficina técnica asignar trabajos de forma más eficiente. De esta forma, el sistema puede ayudar a clasificar trabajos y sugerir una preasignación de tareas a los usuarios según sus competencias. También ayuda a los nuevos usuarios a seguir las reglas de negocio y aplicar las secuencias más eficientes en el proceso de ingeniería. Además, cuando se produce un error en cualquiera de las herramientas CAD o PLM, los pasos de la sesión pueden recuperarse por completo y la causa del error determinarse con eficacia, lo que reduce el tiempo necesario para analizar las causas del error y el tiempo necesario para recuperar el estado del trabajo antes de la situación de error. Todos los pasos se guardan en el sistema.

Hay que destacar uno de los puntos anteriores: la autocomprobación y auto ejecución de las reglas de diseño sin esfuerzo adicional, ya que esto marca una evolución. Inicialmente, el usuario ha confirmado más opciones basándose en un proceso de aprendizaje profundo reforzado (DRL) para el discriminador; sin embargo, el sistema ha aprendido, basándose en las respuestas de V& VC, qué soluciones son más aplicables a un proceso de diseño y ofrece, basándose en reglas generadoras curadas, soluciones cercanas a las previamente aprobadas.

Desde el punto de vista del proveedor de software, las ventajas de las pruebas del sistema CAD se pueden mejorar en función de las secuencias de trabajo del cliente, lo que permite la validación de nuevos desarrollos, la validación de mejoras, las pruebas de caja negra y las pruebas fuera de rango. Desde el Sistema CAD, la retroalimentación de errores por parte del cliente es más completa, ya que se mantiene la información sobre las acciones del usuario, los pasos, los atributos y los parámetros. El sistema dispone de una forma de exportar los datos de error a un entorno de desarrollador, neutralizando los datos sensibles mediante una matriz de transferencia de datos SVG, que permite al usuario enviar datos neutralizados con una precisión del 99 % para la reproducción de incidencias. Otra capacidad generada es la mejora del análisis «Deadman» para las incidencias, errores y problemas de los clientes, que también ayuda a informar al desarrollador CAD, en un informe neutralizado, de las estadísticas de usabilidad de la solución.

# Capítulo 6

## Conclusiones y trabajo futuro

El marco de trabajo final de la tesis ha sido la inteligencia artificial generativa para el diseño del buque, por lo que, nos centraremos en ese tema.

La incorporación de sofisticados sistemas de información, especialmente en el ámbito del diseño naval (tanto civil como militar), ha dado lugar a importantes avances en las bases de datos relacionales que facilitan la identificación de diversos grupos dentro del astillero. Este avance permite generar conjuntos de datos exhaustivos que revelan patrones y relaciones entre entidades dispares, lo que mejora el proceso de diseño.

Sin embargo, esta integración también prolonga la fase de verificación de cada diseño. En la mayoría de los casos, las empresas auxiliares de ingeniería asumen la responsabilidad de gestionar estos diseños, empleando equipos de personal sin experiencia que son guiados por expertos que han recibido formación en el uso de las nuevas herramientas. Aunque esto representa una mejora significativa del proceso en sí, también aumenta el número de revisiones necesarias. La metodología descrita tiene el efecto de crear una serie de modificaciones que abordan defectos que pueden haberse pasado por alto en las fases iniciales del proceso. De este modo, se garantiza que el producto final mantenga su calidad sin pérdida de capacidad en los modelos o gemelos digitales de alta fidelidad.

Durante el desarrollo de la solución GenAI, se ha observado que el sistema es capaz de verificar de forma independiente la información y aplicar criterios coherentes en numerosos elementos. Esta característica sirve para mejorar el control de calidad, ya que los conocimientos procedentes de las puertas de calidad se proporcionan a los usuarios en una etapa temprana de la fase de diseño. Aunque el alcance inicial del diseño era limitado, la complejidad del proceso global de diseño ha demostrado la posibilidad de lograr avances significativos en el proceso de aprendizaje. La realización de este potencial depende de que los usuarios se adhieran a las normas establecidas y de la capacidad del astillero para cumplir las funciones requeridas.

La implementación del sistema integrado GenAI proporciona a los clientes mayores capacidades, diseños más precisos y una reducción de los errores humanos en la transición de la fase de diseño a la de producción. Además, la base de datos de modelos de IA, que registra los problemas de los clientes y permite recuperar con eficacia las secuencias relevantes utilizadas para generar datos, beneficia indirectamente a los desarrolladores de CAD. La eficacia de las

pruebas de verificación y validación puede mejorarse, ya que el motor de IA puede ejecutar estas secuencias de forma autónoma y registrar sistemáticamente los resultados.

Por último, las actualizaciones de las herramientas del sistema pueden validarse comparando los resultados anteriores con los datos del cliente, lo que elimina la necesidad de rehacer los pasos de diseño y construcción. En consecuencia, se reduce el tiempo necesario para los procesos de diseño, verificación y validación. En consecuencia, mejora la calidad general del diseño, lo que permite al personal con menos experiencia adquirir destreza más rápidamente, ya que el sistema proporciona asistencia integrada en toda la herramienta CAD. Esta adaptabilidad permite a los astilleros modificar rápidamente las herramientas de diseño, lo que facilita las actualizaciones y las iteraciones a medida que GenAI aprende a reconocer las distintas metodologías necesarias para lograr los resultados deseados sin comprometer los aspectos experienciales del diseño dentro del astillero.

En el caso de IoT, tanto para la organización en redes o el uso de sensores se puede concluir que:

1. Añadiendo algunas etiquetas de identificación por radiofrecuencia (RFID) a las piezas, se puede mejorar la información del sistema en el cerebro del buque y, si algunos parámetros pueden mejorarse debido a nuevas experiencias conocidas, se pueden descargar en el buque para mejorar el comportamiento del SSIC.
2. Los futuros buques o astilleros inteligentes deberán estar conectados al IoT o no serán inteligentes. Probablemente, la opción más barata para conseguirlo sea utilizar etiquetas RFID, debido a su bajo coste y fácil codificación. Son una solución asequible para un sistema de seguimiento de almacenes, que ayuda al astillero con la trazabilidad de los materiales y reduce el tiempo de recogida de material para los pedidos MBOM.
3. Este tipo de etiqueta no solo puede utilizarse en almacenes para controlar las existencias, sino también en talleres y a bordo, por lo que la inversión en todos los lectores y grabadores resulta realmente rentable.
4. Además, si los sistemas de software fallan debido a que estas etiquetas están fuera de sistema, con un lector manual se puede controlar fácilmente el almacén y hacer imparable la línea de producción, aislándola de otras partes del astillero. Y si se soluciona el problema del software, se puede actualizar el stock del ERP sin ningún esfuerzo adicional.
5. Como ejemplo de IoS, la conectividad en los buques inteligentes se extenderá a la misión comercial para que puedan actuar de forma autónoma en condiciones de operación. Un buque comercial puede transmitir su situación de navegación o sus condiciones de carga.

Todo ello supone una enorme cantidad de información que hay que gestionar y analizar. Hay que desarrollar nuevos programas para obtener el mejor uso posible de dicha información, de modo que el diseño pueda mejorarse a partir de la información sobre su funcionamiento real y pueda auto mantenerse conectándose a la enorme información que hay en la nube, para crear un método que permita que los objetos alcancen cierta inteligencia.

6. El crecimiento del IoS está ligado al aumento de la información y la gestión de Big Data. De alguna manera, el IoS identifica la información y la dirige y ordena a un propósito específico, mientras que el concepto de Big Data es más genérico.
7. Tratar al buque como un ser vivo y tratar de simular sus partes como órganos o células ayuda a introducir un aprendizaje por redes neuronales que puede ajustar cada Sistema (Ship System IoT Cell - SSIC) para trabajar en las mejores condiciones, alargando la vida de sus piezas, evitando que se dañen otras partes del buque y ayudando a hacer un mantenimiento preventivo de cada parte.
8. Las redes neuronales representan un ajuste automatizado de cada grupo simple de cosas, ya que sus parámetros pueden ajustarse para absorber interferencias externas.
9. Otra ventaja es que estos sistemas pueden entrenarse individualmente, creando condiciones comunes, raras e inusuales.
10. La última ventaja es que, si ocurre algo en un buque, puede reproducirse en el astillero basándose en este modelo, y obteniendo una simulación completa de las condiciones. Esto ayuda a enfocar el problema.

En resumen, solo mencionar algunas de las limitaciones exclusivas:

1. Estudio inicial de los requisitos.
2. Inversión inicial.
3. La elección de un paquete de software que pueda satisfacer todos los requisitos de eficacia de cada grupo (diseñadores de CAD, operarios de producción, compradores, etc.) y, al mismo tiempo, estar totalmente integrado con otras partes de este complejo sistema.

A modo de conclusión final de todos los temas expuestos en esta tesis:

- **Ciberseguridad:** El IoT ha aumentado su popularidad debido a su sencillez, bajo coste y grandes resultados con poco esfuerzo, tanto en el ámbito doméstico como en el industrial. No obstante, los dispositivos IoT presentan un conjunto abierto de vulnerabilidades que requieren una costosa implementación para solucionarlas en origen, un elevado consumo energético y una sobrecarga de procesamiento.

Blockchain es una tecnología muy probada en el entorno de las criptomonedas que establece una forma fiable de comprobar el funcionamiento y los datos.

Cuando ambas tecnologías trabajan juntas, IoT y Blockchain, se superan la mayoría de las vulnerabilidades de ambas, generando una implementación en un entorno de confianza, sin altos costes asociados y realmente escalable. Estas dos tecnologías funcionan perfectamente juntas.

- **Sensórica:** este campo está cambiando muy rápidamente, por lo que, para mantenerse al día hay que estar suscrito a páginas especializadas. Otro detalle es que como tiene una aplicación personal se desarrolla de manera muy masiva.

El tercer detalle es que se está apostando por las líneas de sensórica inalámbrica basada

en tecnologías de radiofrecuencia general (RFID) o Bluetooth de baja intensidad (BLE), por lo que, para aplicaciones con un número controlado de sensores reutilizables se opta por los sensores BAP (Battery Assisted Passive), es decir, sensores que sólo funcionan en ciclos o bajo petición con batería, ya que su duración, a nivel profesional, puede ser de meses o años.

Si el número de sensores que se requieren es muy elevado y tienen que ser fungibles, se usan RFID de tipo pasivo que son muy baratos y funcionan perfectamente con receptores locales de corto y medio alcance, con capacidades industriales de resistencia a impactos, así como ambientes con polvo o humedad.

- **Inteligencia Artificial para análisis inteligente del dato:** este campo está creciendo, acercándose al tratamiento humano, con preguntas en lenguaje natural y respuestas adecuadas en lenguaje natural con multi lenguaje y multi formato, desde coloquial a formal, pasando por académico, etc.

Este campo debe seguir estudiándose para conseguir diseño asistido por ordenador realmente asistido, de manera que cualquier idea sea fácil de plasmar en un diseño regulado por las normativas existentes.

Debido a lo anterior, el campo que requiere de un impulso más profundo es el último, por lo que futuras investigaciones se centrarán en ese campo. Como resumen de las líneas de trabajo futuro que se han encontrado durante la redacción de esta tesis:

- Es necesario mejorar los modelos de formación para permitir una mayor adaptabilidad y un aprendizaje temprano, por lo que se seguirán probando métodos de optimización estocástica para mejorar la calidad de los resultados de los modelos VAE y generar mejores procesos basados en requisitos.
- La codificación en lenguaje natural de los requisitos en lenguaje CAD/PM de acciones, pasos, atributos y parámetros, mediante procesos complejos para su aplicación en herramientas de diseño, simulación y PLM, también requiere mejoras. Por este motivo, también se seguirán investigando procesos para aumentar la capacidad.
- Este tipo de comportamiento también amplía el campo fuera del ámbito de la construcción naval, de modo que puede aplicarse a otros sectores que también pueden aprovechar estas capacidades.
- Tras mejorar la ciberseguridad y la fiabilidad de la red empresarial, el funcionamiento común puede analizarse utilizando la inteligencia artificial (IA) y el aprendizaje automático (ML) para estudiar los patrones normales de trabajo, explorar las anomalías de funcionamiento y prevenir los fallos de IoT.
- En última instancia, todas las capas posibles de la Industria 4.0 deben incorporarse a la implementación de la empresa para asegurarnos de que cubrimos de forma eficaz y eficiente todas las necesidades de mejora que este paradigma puede aportar para realizar una automatización de los procesos de soluciones empresariales.

- Continuar con los estudios de interferencia y apantallamiento en antenas de recepción inalámbrica en entornos metálicos, así como estudiar las capacidades que tiene la inteligencia artificial, concretamente, el Marco desarrollado en la tesis, sobre el estudio de los resultados de los datos tomados con la antena.

Seguramente existan otras, pero se han enumerado aquellas que desde el punto de vista del autor son las más relevantes.



# Referencias

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D. G., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., . . . Zheng, X. (2016). TensorFlow: a system for large-scale machine learning. *Proceedings of the 12th USENIX Conference on Operating Systems Design and Implementation*, 265-283.
- Aslam, S., Herodotou, H., Of, On, Garro, E., Romero, A., Burgos, M., Cassera, A., Papas, G., Dias, P., & Michaelides, M. (2023). Internet of Ships: A Survey on Architectures, Emerging Applications, and Challenges.
- Banafa, A. (2017). *IoT and Blockchain Convergence: Benefits and Challenges*. <https://iot.ieee.org/articles-publications/newsletter/january-2017/iot-and-blockchain-convergence-benefits-and-challenges.html>
- Banafa, A. (2018). 8 IoT Standardization and Implementation Challenges. En *Secure and Smart Internet of Things (IoT): Using Blockchain and AI* (pp. 53-58). River Publishers.
- Benayas-Ayuso, A., & Perez Fernandez, R. (2018a). Automated/controlled storage for an efficient MBOM process in the shipbuilding managing the IoT technology. *Smart Ships Conference 2018*, 69-75.
- Benayas-Ayuso, A., & Perez Fernandez, R. (2018b). RFID tagging for a connected shipyard. *Innovation in shipbuilding - A supplement to The Naval Architect, April 2018*(April 2018), 22-23.
- Benayas-Ayuso, A., & Perez Fernandez, R. (2019). What should shipbuilding expect from the CAD/CAM Systems of the future? *The Naval Architect, April 2019*(April 2019), 28-31.
- Benayas-Ayuso, A., Perez Fernandez, R., & Perez-Arribas, F. L. (2018). Data management for smart ship or how to reduce machine learning cost in IoS applications. *Smart Ships Conference 2018*, 101-106.
- Benayas-Ayuso, A., Perez Fernandez, R., & Perez-Arribas, F. L. (2021). Internet of Things Cybersecurity - Blockchain as first securitisation layer of an IoT network. En *Introduction to Internet of Things in Management Science and Operations Research*.
- Benayas-Ayuso, A., Perez Fernandez, R., & Perez-Arribas, F. L. (2024). CAD Sensitization, an easy way to integrate Artificial Intelligence in shipbuilding. *Artificial Intelligence in Industrial IoT Applications*, 13, 273. <https://doi.org/10.3390/computers13100273>
- BlackBox. (2024). *LaserLink FSO and RF Bridges*. <https://www.blackbox.be/en-be/page/22279/Solutions/By-Technology/Networking-Solutions/Wireless-Networking/laserlink-fso-and-rf-bridges>

- Bogdanov, A., Knežević, M., Leander, G., Toz, D., Varıcı, K., & Verbauwhede, I. (2011). SPONGENT: A lightweight hash function. *Cryptographic Hardware and Embedded Systems–CHES 2011: 13th International Workshop, Nara, Japan, September 28–October 1, 2011. Proceedings 13*, 312-325.
- Choi, J. K., & Kim, H. J. (2016). *Analysis of Digital Data Technologies Toward Future Data Eco-Society*.
- Daase., C., Haertel., C., Nahhas., A., Zeier., A., Ramesohl., A., & Turowski., K. On the Current State of Generative Artificial Intelligence: A Conceptual Model of Potentials and Challenges. En: *En Proceedings of the 26th International Conference on Enterprise Information Systems - Volume 1: ICEIS*. INSTICC. SciTePress, 2024, 845-856. <https://doi.org/10.5220/0012707500003690>.
- Delfs, H., & Knebl, H. (2002). *Introduction to Cryptography: Principles and Applications*. Springer Berlin Heidelberg.
- DigitalAir. (2024). *Laser FSO Wireless Links*. <https://www.digitalairwireless.com/articles/blog/laser-fso-wireless-links>
- Dorri, A., Kanhere, S. S., & Jurdak, R. (2017). Towards an Optimized BlockChain for IoT, 173-178. <https://doi.org/10.1145/3054977.3055003>
- Dorri, A., Kanhere, S. S., Jurdak, R., & Gauravaram, P. (2017). Blockchain for IoT security and privacy: The case study of a smart home. *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, 618-623. <https://doi.org/10.1109/PERCOMW.2017.7917634>
- dos Santos e Santos, L., Ribeiro Filho, P. R. C. F., & Macêdo, E. N. (2024). Belt rotation in pipe conveyors: Development of an overlap monitoring system using digital twins, industrial Internet of things, and autoregressive language models. *Measurement*, 230, 114546. <https://doi.org/https://doi.org/10.1016/j.measurement.2024.114546>
- ECC. (2021). *ERC Recommendation 70-03 - Relating to the use of Short Range Devices (SRD)*.
- ECSytem. (2024). *FSO products*. <http://www.ecsystem.cz/en/products/free-space-optic-equipment>
- ESA. (2006). *Another world first for Artemis: a laser link with an aircraft*. [https://www.esa.int/About\\_Us/ESRIN/Another\\_world\\_first\\_for\\_Artemis\\_a\\_laser\\_link\\_with\\_an\\_aircraft](https://www.esa.int/About_Us/ESRIN/Another_world_first_for_Artemis_a_laser_link_with_an_aircraft)
- Fernández, R. P., & Muñoz, J. Á. (2017). The Internet of Ships: a new design for Smart Ship. *The Naval Architect*.
- Fernández-Caramés, T. M., Fraga-Lamas, P., Suárez-Albela, M., & Castedo, L. (2017). Reverse Engineering and Security Evaluation of Commercial Tags for RFID-Based IoT Applications. *Sensors*, 17(1). <https://doi.org/10.3390/s17010028>
- Fischer, A., & Igel, C. (2012). An Introduction to Restricted Boltzmann Machines. En L. Alvarez, M. Mejail, L. Gomez & J. Jacobo (Eds.), *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications* (pp. 14-36). Springer Berlin Heidelberg.
- Foundations of Machine Learning*. (2018). The MIT Press.
- Fraga-Lamas, P., Noceda-Davila, D., Fernández-Caramés, T. M., Díaz-Bouza, M. A., & Vilar-Montesinos, M. (2016). Smart Pipe System for a Shipyard 4.0. *Sensors*, 16(12). <https://doi.org/10.3390/s16122186>

- Garlington, T., Babbitt, M. J., & Long, G. (2005). Analysis of Free Space Optics as a Transmission Technology. *U.S. Army Information Systems Engineering Command (USAISEC), Transmission Systems Directorate, WP No. AMSEL-IE-TS-05001*, 12.
- Gidi, J., Candia, B., Muñoz-Moller, A. D., Rojas, A., Pereira, L., Muñoz, M., Zambrano, L., & Delgado, A. (2023). Stochastic optimization algorithms for quantum applications.
- Harjamäki, J., Rantanen, P., Lahtinen, D., Sillberg, P., Saari, M., Grönman, J., Rasheed, Z., Sami, A., & Abrahamsson, P. (2024). *The Report of 85 AI Tools: GenAI Content Production: Enhancing Repeatability and Automation with ChatGPT* (T. University, Ed.). Tampere University.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., del Río AM HERE!!!!o, J. F., Wiebe, M., Peterson, P., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357-362. <https://doi.org/10.1038/s41586-020-2649-2>
- HBBCI. (2009). *Free-Space Optical Communications*. <https://web.archive.org/web/20090417063155/http://www.seas.harvard.edu/hbbcl/fsoc.html>
- IEC. (2019). *Electrical installations in ships - Part 370: Guidance on the selection of cables for telecommunication and data transfer including radio-frequency cables*.
- IrDAJP. (2019). *IrDA Library of Specifications and Technical Papers*. <https://web.archive.org/web/20191115171139/http://www.irdajp.info/specifications.html>
- ISO/IEC JTC 1/SC 31. (2018). *ISO/IEC 18000-4 2018 Information technology - Radio frequency identification for item management - Part 4 - Parameters for air interface communications at 2.45 GHz*.
- ITU. (2015). *Nomenclature of the frequency and wavelength bands used in telecommunications*.
- ITU. (2020). *Radio Regulations - Articles - Edition 2020 (pending update to new edition released in Q3 2024)*.
- John. (2021). *The Advantages and Disadvantages of Optical Fiber*. <https://community.fs.com/article/the-advantages-and-disadvantages-of-optical-fibers.html>
- Jørgensen, S. E. (2003). *Optisk kommunikation i deep space* (Doctoral Thesis). Niels Bohr Institutet for Astronomi, Fysik og Geofysik.
- Khan, M. A., & Salah, K. (2018). IoT security: Review, blockchain solutions, and open challenges. *Future Generation Computer Systems*, 82, 395-411. <https://doi.org/https://doi.org/10.1016/j.future.2017.11.022>
- Kirsch, D. (2015). The Value of Bringing Analytics to the Edge.
- Komninou, N., Philippou, E., & Pitsillides, A. (2014). Survey in Smart Grid and Smart Home Security: Issues, Challenges and Countermeasures. *IEEE Communications Surveys & Tutorials*, 16(4), 1933-1954. <https://doi.org/10.1109/COMST.2014.2320093>
- Li, X., Jiang, P., Chen, T., Luo, X., & Wen, Q. (2020). A survey on the security of blockchain systems. *Future Generation Computer Systems*, 107, 841-853. <https://doi.org/https://doi.org/10.1016/j.future.2017.08.020>
- Liu, G., Pérez Fernández, R., Muñoz, J. A., & Ragueira, F. (2016). Internet of Ships: The Future Ahead. *World Journal of Engineering and Technology*, 04, 220-227. <https://doi.org/10.4236/wjet.2016.43D027>

- Loeffler, A., & Gerhaeuser, H. (2013). Localizing with Passive UHF RFID Tags Using Wideband Signals. En M. B. I. Reaz (Ed.), *Radio Frequency Identification*. IntechOpen. <https://doi.org/10.5772/53769>
- Lu, D., Teng, L., Tan, J., Wang, M., Tien, Z., & Wang, G. (2024). Infrared Bilateral Polarity Ship Detection in Complex Maritime Scenarios. *Sensors*, 24, 4906. <https://doi.org/10.3390/s24154906>
- Lu, Z., Pu, H., Wang, F., Hu, Z., & Wang, L. (2017). The Expressive Power of Neural Networks: A View from the Width. En I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan & R. Garnett (Eds.), *Advances in Neural Information Processing Systems*. Curran Associates, Inc.
- Mikolajczyk, J., Bielecki, Z., Bugajski, M., Piotrowski, J., Wojtas, J., Gawron, W., Szabra, D., & Prokopiuk, A. (2017). Analysis of Free-Space Optics Development. *Metrology and Measurement Systems*, 24, 22. <https://doi.org/10.1515/mms-2017-0060>
- Nakamoto, S. (2009). Bitcoin : A Peer-to-Peer Electronic Cash System.
- Norouzi, S., Fleet, D. J., & Norouzi, M. (2020). Exemplar VAE: Linking Generative Models, Nearest Neighbor Retrieval, and Data Augmentation. En H. Larochelle, M. Ranzato, R. Hadsell, M. Balcan & H. Lin (Eds.), *Advances in Neural Information Processing Systems* (pp. 8753-8764). Curran Associates, Inc.
- NumFocus.org. (2024). *NumFocus about*.
- Pérez Fernández, R., & Regueira, F. J. (2022). How to improve the shipbuilding industry with the Internet of ships concept. *Ciencia y tecnología de buques*, 15(30), 37-46. <https://doi.org/10.25043/19098642.227>
- Perez-Martinez, J., & Perez Fernandez, R. (2023). Material and Production Optimization of the Ship Design Process by Introducing CADs from Early Design Stages. *Journal of Marine Science and Engineering*, 11(1). <https://doi.org/10.3390/jmse11010233>
- Pérez-Martinez, J., & Pérez Fernández, R. (2021). Shipbuilding 3D CAD Tools as an Integrated Solution from Concept to Product. *Ciencia y tecnología de buques*, 15(29), 45-57. <https://doi.org/10.25043/19098642.220>
- pureLiFi. (2024). *IoT and Blockchain Convergence: Benefits and Challenges*. <https://www.purelifi.com>
- Python.org. (2024). *What is Python*.
- RAE. (2014). *Radiofrecuencia - Definición*. <https://dle.rae.es/radiofrecuencia>
- Roberts, C. M. (2006). Radio frequency identification (RFID). *Computers & security*, 25(1), 18-26.
- Samaniego, M., & Deters, R. (2016). Hosting Virtual IoT Resources on Edge-Hosts with Blockchain. *2016 IEEE International Conference on Computer and Information Technology (CIT)*, 116-119. <https://doi.org/10.1109/CIT.2016.71>
- Shahriari, B., Swersky, K., Wang, Z., Adams, R. P., & de Freitas, N. (2016). Taking the Human Out of the Loop: A Review of Bayesian Optimization. *Proceedings of the IEEE*, 104(1), 148-175. <https://doi.org/10.1109/JPROC.2015.2494218>
- SIG, B. (2024). *Bluetooth Core Specification*.
- Sokolov, Sergey, Antonova, Alena, Knysh, Tatiana & Li, Izolda. (2022). Automation of shipbuilding and shiprepairing using Internet of Ships technology. *E3S Web Conf.*, 363, 01033. <https://doi.org/10.1051/e3sconf/202236301033>

- 
- Taiwo, R., Bello, I. T., Abdulai, S. F., Yussif, A.-M., Salami, B. A., Saka, A., & Zayed, T. (2024). Generative AI in the Construction Industry: A State-of-the-art Analysis.
- TTF. (2009). *Generic Requirements for Optical Cable Innerduct, Associated Conduit, and Accessories*. <https://telecom-info.njdepot.ericsson.net/site-cgi/ido/docs.cgi?ID=SEARCH&DOCUMENT=GR-356&>
- TTF. (2014). *Generic Requirements for Hybrid Optical and Electrical Cables for Use in Wireless Outdoor Fiber To The Antenna (FTTA) Applications*. <https://telecom-info.njdepot.ericsson.net/site-cgi/ido/docs.cgi?ID=SEARCH&DOCUMENT=GR-3173&>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is All you Need. En I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan & R. Garnett (Eds.), *Advances in Neural Information Processing Systems*. Curran Associates, Inc.
- Willebrand, H., & Ghuman, B. (2001). *Free Space Optics: Enabling Optical Connectivity in Today's Networks*. Sams.



# Anexos